

LAPORAN PROGRAM
TAHUN ANGGARAN 2022-2023

RANCANG BANGUN DECISION SUPPORT SYSTEM UNTUK CLUSTERING
TINGKAT KERUSAKAN BANGUNAN PASCA BENCANA ALAM
MENGGUNAKAN DEEP LEARNING
PROGRAM: PENELITIAN PENGEMBANGAN KOLABORATIF INTERNASIONAL



OLEH:

DR. CAHYO CRYSDIAN, MCS (197404242009011008)

ANGGOTA:

AGUNG TEGUH WIBOWO ALMAIS, M.T (19860301201802011235)

PUSPA MILADIN NURAI DA SAFITRI A. BASID, M.KOM (199308282019032018)

PROF. DRS. IR. ADI SUSILO, M.SI., PH.D. (196312271991031002)

PROF. DR.-ING. HENDRO WICAKSONO (3515180306780003)

AMILA FADHILA RAHMANIATI (18650127)

KEMENTERIAN AGAMA
PROJECT MANAGEMENT UNIT (PMU)
THE DEVELOPMENT OF UIN MAULANA MALIK IBRAHIM MALANG
PHASE II EAST JAVA PROJECT
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
2022

HALAMAN PENGESAHAN

Laporan Program Penelitian Pengembangan Kolaboratif Internasional UIN Maulana Malik Ibrahim Malang Tahun 2022-2023 UIN Maulana Malik Ibrahim Malang ini disahkan oleh Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.

Pada tanggal-....-2023

Ketua : Dr. Cahyo Crysdiyan., M.CS
197404242009011008

Anggota I : Agung Teguh Wibowo Almais, M.T
19860301201802011235

Anggota II : Puspa Miladin Nuraida Safitri A. Basid, M.Kom
199308282019032018

Anggota III : Prof. Drs. Ir. Adi Susilo, M.Si., Ph.D.
196312271991031002

Anggota IV : Prof. Dr.-Ing. Hendro Wicaksono
3515180306780003

Anggota V : Amila Fadhila Rahmaniati
18650127

Direktur PMU

Ketua LP2M

UIN MAULANA MALIK IBRAHIM MALANG

UIN MAULANA MALIK IBRAHIM MALANG

Prof. Dr. H. A. Muhtadi Ridwan, M.Ag.
NIP. 195503021987031004

Prof. Dr. H. Agus Maimun, M.Pd
NIP. 196508171998031003

Mengetahui,

Rektor UIN Maulana Malik Ibrahim Malang

Prof. Dr. H. M. Zainuddin, MA.
NIP. 19620507 199203 1 001

PERNYATAAN ORISINALITAS

Kami yang bertanda tangan di bawah ini:

Nama : Dr. Cahyo Crysdiyan. M.CS
NIP : 197404242009011008
NIDN : 0724047401
Pangkat/Gol.Ruang : Lektor Kepala– IV/A
Bidang Keahlian : Intelligence System
Fakultas/Jurusan : Sains dan Teknologi / Magister Teknik Informatika
Jabatan dalam Penelitian : Ketua Pengusul

Menyatakan dengan sebenar-benarnya bahwa dalam program ini tidak terdapat unsur-unsur penjiplakan karya ilmiah yang pernah dilakukan atau dibuat oleh orang lain, kecuali yang secara tertulis disebutkan dalam naskah ini dan disebutkan dalam sumber kutipan dan daftar pustaka. Apabila di kemudian hari ternyata dalam karya ilmiah ini terbukti terdapat unsur-unsur penjiplakan dan pelanggaran etika akademik, maka kami bersedia mengembalikan dana program yang telah kami terima dan diproses sesuai dengan peraturan perundangundangan yang berlaku.

Malang, 08 Agustus 2023

Ketua Peneliti

Dr. Cahyo Crysdiyan. M.CS
NIP. 197404242009011008

DAFTAR ISI

COVER.....	1
HALAMAN PENGESAHAN	2
PERNYATAAN ORISINALITAS	4
DAFTAR ISI	5
DAFTAR TABEL	7
DAFTAR GAMBAR	8
ABSTRAK.....	9
BAB I	10
PENDAHULUAN	10
1.1. Latar Belakang	10
1.2. Perumusan Masalah	14
1.3. Tujuan Penelitian	14
1.4. Batasan Masalah	14
1.5. Kontribusi Penelitian	14
BAB II.....	16
STUDI PUSTAKA DAN ROADMAP	16
2.1. Penelitian Yang Relevan.....	16
2.2. Classification Image	22
2.3. Segmentation Image	22
2.4. Object Detection	22
2.5. Artificial Intelligence, Machine Learning dan Deep Learning	23
2.6. Metode Convolutional Neural Network (CNN)	24
2.7. Roadmap Penelitian	27
BAB III	28
METODOLOGI PENELITIAN.....	28
3.1. Metodologi Teknis	28
3.2. Metodologi Bisnis.....	29
3.3. Kerangka Pikir	30
3.4. Waktu dan Tempat.....	32
3.5. Prosedur Penelitian	32
3.5.1. Studi Literatur.....	33

3.5.2.	Persiapan.....	33
3.5.3.	Pengumpulan Data.....	34
3.5.4.	Analisis dan Perancangan.....	34
3.5.5.	Pra-Processing Data.....	35
BAB IV	36
HASIL DAN PEMBAHASAN	36
4.1.	Pelaksanaa Penelitian	36
4.2.	Hasil Road Map Penelitian.....	36
4.2.	Outcome Penelitian	47
BAB V	50
5.1.	Kesimpulan.....	50
5.2.	Saran.....	50
REFERENCES	51
LAMPIRAN	59

DAFTAR TABEL

Tabel 1.1. Jenis Aplikasi dan Arsitektur Metode Convolutional Neural Network (CNN) .	12
Tabel 4.1. Outcome Penelitian.	42

DAFTAR GAMBAR

Gambar 2.1. Ilustrasi Konsep Machine Learning dan Deep Learning.....	24
Gambar 2.2. Arsitektur <i>Convolutional Neural Network</i> (CNN)	25
Gambar 2.3. Proses Convolution Pada Citra	25
Gambar 2.4. Ilustrasi konsep dari Max Pooling dan Average Pooling	26
Gambar 2.5. Roadmap Penelitian	27
Gambar 3.1. Alur Metodologi Knowledge Discovery and Data Mining (KDD).....	28
Gambar 3.2. Alur Proses Metodologi IBM Data Science	30
Gambar 3.3. Mind Mapping Penelitian	32
Gambar 3.4. Rancangan Penelitian.....	33
Gambar 3.5. Analisis dan Perancangan	34
Gambar 4.1. Arsitektur Labeling menggunakan PCA.....	37
Gambar 4.2. Arsitektur SDDS	40
Gambar 4.3. Arsitektur SASSD.....	37
Gambar 4.4. Arsitektur Sistem	44

ABSTRAK

Decision Support System (DSS) merupakan salah satu cabang keilmuan dari sistem informasi yang memiliki suatu intelligence. Menerapkan DSS untuk memecahkan suatu masalah merupakan satu bentuk riset yang banyak peneliti lakukan. Metode yang banyak di terapkan oleh para peneliti adalah *Multi-Criteria Decision Making* (MCDM), salah satu metode MCDM yaitu *Technique for Order of Preference by Similarity to Ideal Solution* (TOPSIS). Salah satu kelemahan MCDM yaitu user harus melewati setiap langkah dari metode MCDM. Dengan adanya kelemahan tersebut maka peneliti melakukan kolaborasi dengan menerapkan *Machine Learning* (ML) pada DSS, tujuannya adalah agar DSS lebih cerdas karena user tidak perlu melakukan tahapan-tahapan DSS dalam memecahkan masalah. Pada penelitian kami menggunakan obyek untuk menentukan tingkat kerusakan sektor pasca bencana alam menggunakan *Deep Learning* (DL). Sebelum menerapkan metode DL yaitu *Convolutional Neural Network* (CNN) untuk menentukan tingkat kerusakan sektor pasca bencana alam adalah melakukan pre-processing data. terdapat beberapa langkah dari *pre-processing* data diantaranya labeling data, dan augmentasi data. Dengan menggunakan data hasil dari DSS untuk mencari labeling data pada setiap data kerusakan sektor pasca bencana alam menggunakan *Principal Component Analysis* (PCA) agar pada saat melabelkan tingkat kerusakan sektor pasca bencana memiliki acuan secara ilmiah. Setelah mendapatkan labeling data tingkat kerusakan sektor pasca bencana alam menggunakan PCA kemudian menggunakan hasil reduksi parameter dari teknik PCA tersebut untuk acuan augmentasi gambar agar gambar dapat terbentuk sesuai dengan parameter yang digunakan. Kemudian hasil dari augmentasi gambar tersebut akan masuk proses watershed algoritma untuk mengetahui tingkat kerusakan sektor pasca bencana alam.

Kata Kunci: *Decision Support System (DSS), Multi-Criteria Decision Making (MCDM), TOPSIS, Machine Learning (ML), Deep Learning (DL), Principal Component Analysis (PCA)*

ABSTRACT

Decision Support System (DSS) is a scientific branch of information systems that has intelligence. Applying DSS to solve a problem is a form of research that many researchers do. The method that is widely used by researchers is Multi-Criteria Decision Making (MCDM), one of the MCDM methods, namely the Technique for Order of Preference by Similarity to Ideal Solution (TOPSIS). One of the weaknesses of MCDM is that the user has to go through each step of the MCDM method. Given these weaknesses, the researchers collaborated by implementing Machine Learning (ML) on DSS, the goal is to make DSS smarter because users do not need to carry out DSS stages in solving problems. In our research, we use objects to determine the level of damage to the sector after natural disasters using Deep Learning (DL). Before applying the DL method, namely the Convolutional Neural Network (CNN), to determine the level of damage to a sector after a natural disaster, it is necessary to pre-process the data. there are several steps of data pre-processing including data labeling and data augmentation. By using data from the DSS to search for data labeling in each post-natural disaster sector damage data using Principal Component Analysis (PCA) so that when labeling the level of damage to the post-disaster sector has a scientific reference. After obtaining labeling data on the level of damage to the post-natural disaster sector using PCA, they are then using the parameter reduction results from the PCA technique as a reference for image augmentation so that images can be formed according to the parameters used. Then the results of the image augmentation will enter the watershed algorithm process to determine the level of damage to the sector after natural disasters.

Keyword: *Decision Support System (DSS), Multi-Criteria Decision Making (MCDM), TOPSIS, Machine Learning (ML), Deep Learning (DL), Principal Component Analysis (PCA)*

BAB I

PENDAHULUAN

1.1. Latar Belakang

Indonesia merupakan salah satu negara yang erat kaitannya dengan bencana alam seperti gunung meletus, banjir, kebakaran, angin puting beliung, dan tanah longsor (Bachriwindi et al., 2019). Menurut (Safitri et al., 2022) sekitar 13% gunung berapi didunia terdapat di negara Indonesia sehingga dapat memicu menimbulkan bencana alam dengan intensitas kekuatan berbeda-beda. Banyak dampak yang diakibatkan dari adanya bencana alam salah satunya adalah kerusakan dan kerugian sektor atau bangunan (Safitri et al., 2022). Untuk menentukan tingkat kerusakan sektor pasca bencana dilakukan oleh surveyor yang terdiri dari relawan, Badan Penanggulangan Bencana Daerah (BPBD), masyarakat, dan pihak yang berkaitan (Wibowo Almais et al., 2016). Menurut (Almais et al., 2020) untuk menentukan tingkat kerusakan sektor pasca bencana alam terdapat 5 kriteria yaitu 1). Keadaan bangunan 2). Keadaan struktur bangunan 3). Keadaan fisik bangunan rusak sebesar 4). Fungsi bangunan 5). Keadaan penunjang lainnya. Masing-masing kriteria tersebut akan digunakan acuan dalam menentukan tingkat kerusakan sektor menggunakan *citra digital* berbasis *deep learning*. Kriteria-kriteria tersebut akan di tranformasikan pada citra digital sektor yang terdampak bencana alam untuk di ketahui tingkat kerusakan sektor tersebut.

Beberapa penelitian tentang sistem management disaster yang sudah ada masih fokus pada pengelolaan barang dan evakuasi korban bencana alam. Salah satunya adalah *Decision Support System* (DSS) untuk menentukan kelayakan tempat evakuasi bagi para korban bencana alam (Hadiguna et al., 2014). Pada penelitian (Hadiguna et al., 2014) dibangun sebuah *Decision Support System* (DSS) menggunakan metode *Multi Exprt-Multi Criteria Decision Making* (ME-MCDM) untuk menentukan layak atau tidak layer tempat ibadah sebagai tempat evakuasi korban bencana alam. Selain tempat evakuasi korban bencana alam dapat di deteksi kelayakannya menggunakan *Decision Support System* (DSS), pada (Bachriwindi et al., 2019) menerapkan *Decision Support System* (DSS) untuk menentukan tingkat kerusakan sektor pasca bencana alam dengan metode *Weighted Product* (WP) yang menghasilkan nilai *precision* 56.50%, *recall* 50.50%, *accuracy* 53.30%, dan *f-measure* 39.10% dengan menggunakan 373 data. Pada penelitiannya (Almais et al., 2019) mengembangkan penelitian (Bachriwindi et al., 2019) dengan menggabungkan (*hybrid*) antara *fuzzy logic* dengan metode *Weighted Product* (WP) yang menghasilkan tingkat

accuracy lebih baik dan lebih cepat karena menggunakan range nilai antara 0-1 yang tidak membutuhkan memori atau *resource* komputer yang besar.

Pada penelitiannya (Bachriwindi et al., 2019) terdapat kekurangan yaitu surveyor masih melakukan banyak langkah pada metode *Multi Criteria Decision Making* (MCDM) dalam menentukan tingkat kerusakan sektor pasca bencana alam yang menyebabkan hasil pengujiannya kecil, selain itu data yang digunakan masih bentuk text atau excel data kerugian sektor pasca bencana alam Provinsi Jawa Timur. Berdasarkan kekurangan tersebut maka akan meneliti dengan mengganti input untuk menentukan tingkat kerusakan sektor pasca bencana menggunakan *citra digital* (gambar) yang di proses menggunakan *Artificial Intelligence* (AI) agar dapat seperti kecerdasan manusia yang mampu menentukan jenis kerusakan pada sebuah sektor atau bangunan.

Pada penelitian (Premachandra et al., 2015) bahwa untuk mendeteksi retak (*crack*) pada sebuah permukaan jalan dapat dengan cara mengekstraksi citra permukaan jalan yang retak (*crack*) dengan membandingkan citra permukaan jalan yang berbeda. Terdapat salah satu cara untuk menentukan kerusakan pada sebuah bangunan jika di teknik sipil dapat menggunakan metode *CrackIT*, tetapi pada penelitiannya (Abdellatif et al., 2021) metode *CrackIT* memiliki kelemahan yaitu tingkat akurasi yang dihasilkan tidak akurat dengan kondisi sebenarnya. Sehingga pada penelitian (Abdellatif et al., 2021) diusulkan untuk menggunakan *deep learning* untuk mengetahui keretakan pada sebuah bangunan. Pada bidang geofisika, *deep learning* dapat untuk menentukan jenis bencana yang sudah melanda pada suatu daerah dengan cara mendeteksi gambar bangunan yang terdampak bencana alam (Valdez and Godmalin, 2021).

Model *deep learning* dapat dibangun menggunakan metode *Convolutional Neural Network* (CNN), pada penelitian (Gupta et al., 2021) metode *Convolutional Neural Network* (CNN) di gunakan untuk menentukan keadaan jalur atau jalan evakuasi setelah bencana alam di Provinsi Palu menggunakan *open data satellite OSM*. Penerapan *deep learning* pada (Gupta et al., 2021) menggunakan aktifasi Relu untuk menerapkan arsitektur *Convolutional Neural Network* (CNN). Arsitektur *Convolutional Neural Network* (CNN) merupakan suatu cara atau teknik dalam memecahkan problem yang menggunakan *deep learning*. Menurut (Faticah, 2021) metode *Convolutional Neural Network* (CNN) memiliki beberapa aplikasi dan setiap aplikasi memiliki arsitektur masing-masing. Pada tabel 1. berikut merupakan jenis aplikasi dan arsitektur pada metode *Convolutional Neural Network* (CNN).

Tabel 1.1. Jenis Aplikasi dan Arsitektur Metode *Convolutional Neural Network* (CNN)

No.	Tipe Aplikasi	Arsitektur Metode <i>Convolutional Neural Network</i> (CNN)
1.	<i>Image Classification</i>	<ul style="list-style-type: none"> • <i>LeNet-5</i> • <i>AlexNet</i> • <i>GoogLeNet/ Inception</i> • <i>VGGNet</i> • <i>ResNet</i>
2.	<i>Semantic (Instance) Segmentation</i>	<ul style="list-style-type: none"> • <i>Fully Convolutional Network (F-CN)</i> • <i>U-Net</i> • <i>Feature Pyramid Network (FPN)</i> • <i>Mask R-CNN</i> • <i>DeepLab, DeepLabv, DeepLabv3+</i>
3.	<i>Object Detection</i>	<ul style="list-style-type: none"> • <i>R-CNN</i> • <i>Fast R-CNN</i> • <i>Faster R-CNN</i> • <i>Single Shot Detector (SSD)</i> • <i>YOLO</i>
4.	<i>Generative Model</i>	<ul style="list-style-type: none"> • <i>Autoencoder, Variational Autoencoder (VAE)</i> • <i>Generative Adversarial Network (GAN)</i>

Pada tipe aplikasi *classification image* memiliki beberapa arsitektur untuk menganalisis hasil *classification*, pada penelitiannya (Tripathi, 2021) dijelaskan bahwa teknik untuk proses *classification image* yaitu masing-masing arsitektur tersebut dapat di bandingkan pada suatu studi kasus tertentu untuk di uji menggunakan *confusion matrix*. Pada *classification image* terdapat istilah augmentation data, augmentation data dapat diletakkan pada sebuah server online atau offline karena hasil augmentation data akan digunakan sebagai data training (Han et al., 2018). Jadi data *training* diletakkan pada sebuah server (*google* atau *hosting*), sedangkan data *testing* diletakkan beda server (offline) kemudian dilakukan proses *Convolutional Neural Network* (CNN) menggunakan arsitektur *Alexnet*, *VGG-16*, dan *ResNet* untuk mendapatkan tingkat akurasi terbaik (Han et al., 2018).

Selain *classification image* untuk aplikasi metode *Convolutional Neural Network* (CNN) dapat menggunakan *segmentation*, pada *segmentation* dibagi menjadi dua yaitu

semantic segmentation dan *instance segmentation* (Noh et al., 2015). *Semantic segmentation* merupakan masalah mendasar dari pengolahan citra digital yang belum terselesaikan, karena didalam *semantic segmentation* mendefinisikan masalah klasifikasi yang berfokus pada penetapan label disetiap pixel dengan memberi label dan menerapkannya pada berbagai aplikasi (Hu et al., 2018). *Semantic segmentation* dapat digunakan untuk merubah pixel yang kualitasnya buruk menjadi sama kualitasnya dengan pixel yang masih dalam satu kategori, untuk merubah maka dapat menggunakan jaringan *encode-decoder* (Xu et al., 2021). Untuk membuat jaringan *encode-decoder* dapat menggunakan arsitektur yang dinamakan *SE-ResNet* (Xu et al., 2021). Penerapan dari *segmentation* sangat banyak diantaranya dapat digunakan untuk mengidentifikasi batu pasir berdasarkan *sedimentary petrologi* (Saxena et al., 2021). Pada penelitian (Tian et al., 2020) *segmentation* dapat digunakan untuk memisahkan bunga secara otomatis menggunakan *instance segmentation* dengan arsitektur R-CNN. Data yang digunakan sebanyak 200 gambar menghasilkan nilai *precision* 96.43%, *recall* 95.37%, dan *F-Score* 95.90% (Tian et al., 2020).

Aplikasi metode *Convolutional Neural Network* (CNN) selanjutnya adalah *detection object*, menurut (Chalavadi et al., 2022) *detection object* merupakan suatu hal yang menantang karena okupansi pixel bervariasi untuk setiap object, distribusi object berbeda pada setiap gambar, penampakan gambar yang berbeda dari sudut pandang dan kondisi yang berbeda, dan jumlah object akan berbeda-beda walaupun gambar itu sama. Pada (Chalavadi et al., 2022) mengusulkan metode mSODANET untuk mengakomodasi 4 hal yang ada di *detection object* tersebut agar tidak ada perbedaan *experiment* dari segi apa pun pada saat gambar di proses menggunakan *detection object*.

Banyak arsitektur yang digunakan pada metode *Convolutional Neural Network* (CNN) tapi permasalahannya masih belum ada cara untuk menentukan arsitektur yang cocok untuk setiap problem yang digunakan. Untuk menentukan arsitektur dan *hyperparameter Convolutional Neural Network* (CNN) yang digunakan untuk suatu *classifikasi image* dapat menggunakan teknik optimasi yaitu metode *meta heuristic* seperti *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO) (Gonçalves et al., 2022). Pada penelitiannya (Gonçalves et al., 2022) teknik optimasi yaitu GA dan PSO digunakan untuk menentukan arsitektur *Convolutional Neural Network* (CNN) yang baik dan sepenuhnya terhubung dengan metode CNN. Dengan menerapkan teknik optimasi tersebut didapat kenaikan *f1-score* dari masing-masing arsitektur CNN dalam mendeteksi kanker otak yang digunakan yaitu *VGG 16*, *ResNet-50* dan *DenseNet-201*. Teknik optimasi selain dapat digunakan untuk

menentukan jenis arsitektur CNN yang cocok dan dapat terhubung sepenuhnya dengan metode CNN.

Berdasarkan latar belakang diatas maka dapat dilakukan penelitian untuk menentukan tingkat kerusakan sektor pasca bencana alam menggunakan metode *Convolutional Neural Network* (CNN) diantaranya pada data *pre-processing, classification image, segmentation, dan detection object*. Agar penggunaan arsitektur *Convolutional Neural Network* (CNN) yang baik dan sepenuhnya dapat terhubung dengan metode *Convolutional Neural Network* (CNN) dapat menggunakan teknik optimasi. Dari hasil teknik optimasi nanti akan diketahui arsitektur *Convolutional Neural Network* (CNN) mana yang bagus dan akurat untuk menentukan tingkat kerusakan sektor pasca bencana alam.

1.2. Perumusan Masalah

1. Bagaimana merancang dan membangun decision support system untuk clustering tingkat kerusakan bangunan pasca bencana alam menggunakan *deep learning*.
2. Bagaimana menganalisis hasil tingkat akurasi merancang dan membangun decision support system untuk clustering tingkat kerusakan bangunan pasca bencana alam menggunakan *deep learning*.

1.3. Tujuan Penelitian

1. Merancang dan membangun decision support system untuk clustering tingkat kerusakan bangunan pasca bencana alam menggunakan *deep learning*.
2. Menganalisis hasil tingkat akurasi merancang dan membangun decision support system untuk clustering tingkat kerusakan bangunan pasca bencana alam menggunakan *deep learning*.

1.4. Batasan Masalah

1. Menggunakan 2 sumber data dari sumber data online (*Kaggle, Google*) dan data dari hasil survey.
2. Untuk mendeteksi bangunan setelah terjadi bencana alam (pasca) dan tidak untuk mendeteksi jumlah korban jiwa.

1.5. Kontribusi Penelitian

Hasil penelitian ini berkontribusi terhadap 2 bidang keilmuan yaitu teknik informatika dan teknik geofisika. Untuk bidang keilmuan teknik informatika, hasil penelitian berperan dalam peningkatan pengetahuan tentang penerapan arsitektur *Convolutional Neural Network* (CNN) untuk menentukan tingkat kerusakan sektor pasca bencana alam. Sedangkan untuk teknik geofisika dapat menjadi keterbaruan keilmuan dalam menentukan

tingkat kerusakan sektor pasca bencana alam menggunakan *Artificial Intelligence* (AI) yang sebelumnya masih mengandalkan data manual dari surveyor dalam menentukan tingkat kerusakan sektor pasca bencana alam. Selain pada 2 bidang keilmuan tersebut penelitian ini juga berkontribusi buat pemerintah (BPBD) dalam melakukan pendataan rehabilitasi dan rekonstruksi sektor pasca bencana alam dengan mengetahui tingkat kerusakan sektor dengan lebih akurat dan cepat.

BAB II

STUDI PUSTAKA DAN ROADMAP

2.1. Penelitian Yang Relevan

Augmentation data merupakan salah satu *preprocessing data* dalam data science, pada penelitiannya (Pan et al., 2022) *augmentation data* digunakan untuk memprediksi kondisi oli pada sebuah mesin. Dengan memanfaatkan *augmentation data* dengan dikompilasi sebuah pengetahuan, maka dapat digunakan untuk memprediksi kondisi dan siklus oli pada sebuah mesin. Jadi jika hasil *augmentation* bagus maka data training yang digunakan *machine learning* juga bagus. Setelah *augmentation data* selesai maka langkah selanjutnya adalah menghilangkan noise pada data. Untuk menghilangkan noise pada hasil *classification image* dapat menggunakan *polynomials racah* seperti dijelaskan pada penelitian (Batioua et al., 2018) bahwa dengan mengkombinasikan momen varian diskrit klasik dan moment variant diskrit berdasarkan *polynomial racah* dapat meningkatkan tingkat akurasi dengan mensimulasikan pada *image classification* pada gambar *butterfly*. Selain *augmentation data* dalam preprocessing data terdapat teknik *Principal Component Analysis* (PCA), PCA menurut (Uddin et al., 2017) merupakan teknik untuk mengurangi dimensi kumpulan data, meningkatkan kemampuan interpretasi, dan meminimalkan kehilangan informasi pada data. Dalam bidang geofisika (Troccoli et al., 2022) menggunakan *Principal Component Analysis* (PCA) untuk mengelompokkan *seismic fasies* dengan memberi label otomatis dan ukurannya agar dapat mengelompokkan dan menyajikan peta seismis secara rapi dan bagus.

Petrologi sedimen adalah dasar yang sebagian besar mineral untuk mengidentifikasi tekstur di batu pasir. Pada penelitiannya (Saxena et al., 2021) untuk mengidentifikasi tekstur batu pasir biasanya menggunakan suatu aplikasi praktis mengintegrasikan antara ilmu geologi dengan citra 3D (*mikro-CT, nano-CT*). Pada penelitiannya (Saxena et al., 2021) mengusulkan menggunakan gambar 2D untuk mengidentifikasi tekstur dari batu pasir yang diolah menggunakan metode *Convolutional Neural Network* (CNN). Dengan menerapkan arsitektur *Convolutional Neural Network* (CNN) yaitu *Resnet-18* dan *Deeplab V3+* maka dihasilkan tingkat keakuratan yang lebih bagus dari pada menggunakan gambar 3D. Aplikasi *Convolutional Neural Network* (CNN) yang digunakan yaitu *segmentation*, karena gambar 2D akan disegemntasi menjadi 10 kelas untuk dibedakan antara mineral dan pori-porinya.

Kelemahannya adalah tidak membahas jenis batuanya apa tapi hanya memisahkan antara mineral dengan tenstur batu pasir saja. selain itu hanya menerapkan du arsitektur *Convolutional Neural Network* (CNN) yaitu Resnet-18 dan Deeplab V3+.

Pada penelitiannya (X. Li et al., 2021) (Sun et al., 2021) kasusnya hampir sama yaitu model deteksi COVID-19 menggunakan citra rontgen dada selain memiliki kelebihan percitraan yang tepat, biaya rendah dan akurasi tinggi tetapi memiliki kekurangan seperti lemah ketahanan, kemampuan generalisasi yang tidak dapat diandalkan, dan waktu pelatihan yang lama. Untuk mengatasi itu pada (X. Li et al., 2021) meneliti dengan menggunakan 2 pendekatan yaitu *Depthwise Separable Convolutional Neural Network* (DCNN) yang menguji dengan 3 arsitektur *Convolutional Neural Network* (CNN) yaitu *LeNet-5*, *VGG-16*, dan *ResNet-18*. Kedua menggunakan *Dilated and Depthwise Separable Convolutional Neural Network* (DDCNN) dengan menggunakan 2 arsitektur *Convolutional Neural Network* (CNN) yaitu *VGG-16* dan *ResNet-18*. Hasilnya dapat meningkatkan akurasi deteksi dan mengurangi waktu pelatihan. Tetapi pada penelitian (Sun et al., 2021) untuk mengatakan kekurangan dari dari citra *rontgen* tersebut menggunakan dua pendekatan yaitu *factor optimasi momentum beografi* dan *optimasi beografi*. Kedua hal tersebut kemudian di modelkan menggunakan arsitektur *Convolutional Neural Network* (CNN) yaitu *LeNet-5*, *VGG-16*, dan *ResNet-18*. Hasil dari model tersebut menghasilkan bahwa akurasi dari *factor optimasi momentum beografi* lebih unggul dibandingkan dengan akurasi dari *optimasi beografi*.

Dapat dilihat pada penelitian (X. Li et al., 2021) (Sun et al., 2021) bahwa arsitektur *Convolutional Neural Network* (CNN) yang banyak diterapkan adalah *LeNet-5*, *VGG-16*, dan *ResNet-18* karena berdasarkan keterangan (Sun et al., 2021) bahwa ketiga arsitektur tersebut struktur model jaringannya bertahap dan kompleks, selain itu jumlah lapisan jaringan dapat diperdalam secara bertahap. Oleh karena itu, diperoleh hasil percobaan yang efektif dan meyakinkan. Pada penelitiannya (Das et al., 2021) arsitektur *VGG 16* memiliki tingkat akurasi lebih baik dibanding dengan arsitektur *ResNet-50* untuk mengidentifikasi pasien penderita COVID-19 menggunakan gambar rontgen dada pasien. Hasil identifikasi menggunakan model *VGG-16* memberikan *accuracy* sebesar 97,67%, *precision* 96,65%, *recall* 96,54% dan *F1-score* 96,59%.

Arsitektur metode *Convolutional Neural Network* (CNN) salah satunya adalah *Res Net-50*. Pada penelitiannya (Charles et al., 2022) *ResNet-50* digunakan untuk menentukan penyakit jantung menggunakan aplikasi *Convolutional Neural Network* (CNN) yaitu

classification image. Pada penelitiannya (Sarvani et al., 2022) mengimplementasikan empat arsitektur yang ada di *deep learning* digunakan untuk membedakan kasus COVID dan *Non-COVID* yaitu *ResNet-50*, *VGG-16*, *CNN*, dan *CAENNs* dengan menggunakan citra x-ray. Sedangkan *Machine Learning* menggunakan metode *classification SVM*, *NN*, *RF*, *SGD*, *LR*, dan *MLP*. Hasil akurasi masing-masing arsitektur sebesar 92,24%, 94,07%, 93,84%, dan 93,04%. Hasilnya *accuracy* tertinggi di miliki oleh *deep learning* menggunakan arsitektur *Convolutional Neural Network* (CNN). Pada penelitiannya (Victor Ikechukwu et al., 2021) untuk memastikan konvergensi yang tepat pada citara sinar-X, CT-Scan dan Ultasonografi awalnya menggunakan *deep learning* dengan metode *Convolutional Neural Network* (CNN) tapi sangatlah sulit karena membutuhkan lebih banyak waktu komputasi, jumlah besar data pelatihan berlabel dan tingkat pengalaman yang cukup. Maka dengan menggunakan model data *pra-processing* yang diolah dengan arsitektur *Convolutional Neural Network* (CNN) yaitu *VGG-15* dan *ResNet-50* yang dibandingkan dengan data training maka didapat 92.03% tingkat akurasinya. Selain itu juga dapat mengurangi *overfitting*, *augmentation data* dan *dropout regularization*. Pada penelitiannya (Victor Ikechukwu et al., 2021) tidak ada keterangan kenapa menggunakan arsitektur *VGG-16* dan *ResNet-50*.

Media social (twitter) merupakan salah satu *media social* yang aktif memberi kabar dari hasil posting atau upload gambar atau teks dari para pengguna tentang kejadian disekitar kita termasuk bencana alam. Pada penelitiannya (Ahmad et al., 2022) dengan menggabungkan informasi teks dan gambar yang diolah menggunakan *image classification* berbasis *deep learning*, menghasilkan suatu informasi korban jiwa, kerusakan infrastruktur, dan yang berkaitan dengan akibat dari bencana alam. Dengan menggunakan percobaan data *benchmark* menunjukkan hasil bahwa perpaduan teks dan gambar (*multi-modal*) lebih efektif dari pada menggunakan *uni-modal* (teks saja atau gambar saja). Berdasarkan jurnal tersebut dapat dilakukan suatu riset yaitu menentukan kerusakan sektor pasca bencana alam menggunakan gabungan kriteria dari Kementrian Pekerjaan Umum (PU) dengan gambar kerusakan sektor pasca bencana (Bachriwindi et al., 2019). Teknik yang digunakan adalah menggunakan *clustering*, yaitu mengklasifikan *data training* berdasarkan kriteria dari Kementrian Pekerjaan Umum (PU) dengan melabelkan berdasarkan kriterianya (*pre-processing*). Setelah itu hasil *clustering* akan diproses menggunakan *image classification* untuk mendapatkan *data training* yang bagus.

Pada penelitiannya (Liu and Wu, 2016) untuk proses mendapatkan data *preprocessing* dapat menggunakan *transformasi wavelet* yang digunakan untuk menangkap

lebih banyak fitur yang tersembunyi pada image tanah longsor. Setelah fitur tersebut di ketahui maka di *classifier* berdasarkan kelas-kelas untuk di lakukan *forecasting* pada setiap kelas. Input yang digunakan adalah hasil penginderaan jauh dari *Google Earth*.

Untuk mendeteksi gambar atau image yang tumpang tindih dapat menggunakan aplikasi pada *Convolutional Neural Network* (CNN) yaitu *segmentation*. Pada penelitiannya (Upschulte et al., 2022) menyajikan sebuah konsep sederhana menggunakan *segmentation instance* yang disebut *Contour Proposal Network* (CPN) untuk mendeteksi kemungkinan object yang tumpang tindih dalam satu gambar sekaligus dengan tidak merubah ukuran dan object tersebut. Hasil yang didapat ternyata *Contour Proposal Network* (CPN) lebih bagus tingkat akurasi pada *segmentation instance* dibandingkan menggunakan arsitektur *Convolutional Neural Network* (CNN) yang lain seperti *U-Net*, *Mask R-CNN*, dan *StarDist*. Input yang digunakan merupakan sebuah *contour object* maka arsitektur *Contour Proposal Network* (CPN) dapat diterapkan pada semua problem yang ada diluar biomedis.

Pada penelitiannya (Chu et al., 2021) untuk mendeteksi pejalan kaki pada suatu tempat (*Cityscapes*) dapat menggunakan *segmentation instance*, karena dengan menggunakan *segmentation instance* dapat dengan mudah mendeteksi tanpa menggunakan anotasi. Dengan menggunakan pendekatan *Part Mask R-CNN* yaitu pengembangan dari *Mask R-CNN*, dapat meningkatkan akurasi dari arsitektur *Mask R-CNN* yang sudah pernah digunakan. Selain itu dengan menggunakan *segmentation instance* dan arsitektur *Past Mask R-CNN* dapat mengurangi penggunaan *detector holistik* yang biasanya digunakan dalam proses *deep learning*.

Menggabungkan beberapa model jadi satu merupakan teknik yang terkenal dapat meningkatkan kerja suatu teknik atau metode dalam menyelesaikan suatu masalah. Pada penelitiannya (Hendria et al., 2021) menjelaskan tentang penggabungan dua pendekatan untuk memprediksi suatu object pada sebuah citra UAV menggunakan *detection object*. Dengan menggunakan pendekatan yang berasal dari perpaduan model berbasis *transformator* dan *Convolutional Neural Network* (CNN) yang menghasilkan dua pendekatan yaitu menggunakan arsitektur *Swin Transformator* dan *DetectoRS*. Dua arsitektur tersebut akan di lakukan experiment letaknya di pindah untuk mendapatkan model *Convolutional Neural Network* (CNN) yang lebih baik yang dibandingkan dengan model dasarnya.

Permasalahan yang mendasar dari *image processing* adalah mengklasifikasikan kategori suatu gambar agar sama seperti di dunia nyata. Pada penelitiannya (Ma et al., 2013)

membuat suatu inovasi yaitu mengenali image berdasarkan dunia nyata menggunakan pencocokan pixelnya antar gambar, dengan mengadopsi metode *Two-Dimensional Continuous Dynamic Programming* (2DCDP) menghasilkan hasil yang optimal dengan menangkap pixel yang sesuai area yang tidak sama dalam gambar input kemudian dibandingkan dengan gambar *reference* yang mewakili object tanpa menggunakan *segmentation*.

Penggunaan data sebelum yang akan di data *reference* dan digunakan sebagai template untuk menentukan hasil berdasarkan data terbaru merupakan suatu inovasi terbaru. Pada penelitiannya (L. Li et al., 2021) dengan menggunakan data *reference* dan template sebagai input untuk memetakan posisi *distribusi semantic* dari gambar *reference* yang sesuai. Dengan menggunakan arsitektur *Convolutional Neural Network* (CNN) yaitu *ResNet-50* dan *DeepLab13+* yang di kombinasi dengan *semantic template matching framework* dapat digunakan sebagai ide pemecahan masalah baru untuk pengolahan *image processing*.

Pada penelitiannya (Wang et al., 2022) dijelaskan bahwa arsitektur *Convolutional Neural Network* (CNN) terdapat dua macam yaitu menggunakan dua tahap dan satu tahap. Untuk dua tahap arsitektur yang digunakan yaitu *R-CNN*, *Fast R-CNN* dan *Faster R-CNN*, sedangkan satu tahap yang menggunakan *Convolutional Neural Network* (CNN) untuk memprediksi secara langsung kategori dan lokasi target seperti *YOLO* dan *SSD*. Secara umum, untuk dua tahap memiliki tingkat *accuracy* yang lebih tinggi, tetapi membutuhkan waktu yang lebih lama, sedangkan satu tahap tidak membutuhkan waktu yang lama tetapi akurasi berubah-ubah tergantung obyek. Sehingga pada penelitiannya (Wang et al., 2022) membandingkan tingkat *accuracy* arsitektur *Convolutional Neural Network* (CNN) model dua tahap menggunakan *R-CNN* dengan model satu tahap menggunakan *YOLOV3* yang digunakan untuk mendeteksi keausan suatu lapisan besi pada sebuah alat.

Salah satu arsitektur *Convolutional Neural Network* (CNN) yaitu *YOLO* memiliki kelebihan yang bagus dibandingkan dengan arsitektur *Convolutional Neural Network* (CNN) yang lainnya pada penerapan problem tertentu. Pada penelitiannya (Mirhaji et al., 2021) *YOLO-V3* digunakan untuk mendeteksi *image* pohon jeruk untuk mengetahui jumlah jeruk yang ada di pohon tersebut walaupun image yang digunakan kurang pencahayaan atau dimalam hari. Hasilnya tingkat *precision*, *recall*, *f1-score* dan *mAP* sangat bagus yaitu 91.23%, 92.8%, 92%, dan 90.8%. *YOLO* dapat di kembangkan menjadi *ERF-*

YOLO yang merupakan suatu arsitektur *Convolutional Neural Network* (CNN) yang dapat menangani problem data yang digunakan sedikit (Chai et al., 2021).

Sedangkan arsitektur *Mask R-CNN* merupakan salah satu arsitektur yang digunakan untuk *segmentation instance*. Keunggulan dari arsitektur *Mask R-CNN* memiliki tingkat perbandingan hasil yang lebih bagus jika dibandingkan dengan arsitektur lain yang digunakan pada *segmentation instance* di lingkungan yang kompleks (Qiao et al., 2019). Arsitektur *Mask R-CNN* juga memiliki kelemahan yaitu membutuhkan waktu yang lama dalam prosesnya karena membutuhkan parameter yang banyak (Fan et al., 2021) (Yu et al., 2019) karena kelemahan tersebut maka pada penelitiannya (Xiao et al., 2022) memperbaiki arsitektur *Mask R-CNN* dengan mengimprove atau memodifikasi arsitektur *Mask R-CNN* dengan mengkolaborasikan metode *pre-processing SVM*. Pada penelitian (Xiao et al., 2022) *Mask R-CNN* digunakan untuk mengammbil gambar punggung sapi kemudian hasilnya di olah menggunakan metode *SVM* untuk memprediksi keadaan dari sapi tersebut.

Dalam penerapan arsitektur *Convolutional Neural Network* (CNN) pada sebuah problem menggunakan percobaan yang banyak sampai menemukan nilai *accuracy* yang bagus diantara arsitektur *Convolutional Neural Network* (CNN) yang digunakan. Hal itu menjadi salah satu problem dari penerapan arsitektur di metode *Convolutional Neural Network* (CNN). Pada (Gonçalves et al., 2022) dijelaskan untuk mencari suatu arsitektur *Convolutional Neural Network* (CNN) yang cocok dan dapat terhubung dengan mtode *Convolutional Neural Network* (CNN) yang tepat dapat menggunakan teknik optimasi yaitu *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO).

Jenis metode *meta-heuristic* itu ada yang disebut *ant colony* atau kelompok semut. Pada (Aly et al., 2019) metode *meta-heuristic* (*Particle Swarm Optimization* (PSO), *Ant colony*, dan *Bee Colony*) digunakan untuk memprediksi hasil ekstrak fitur dari proses *segmentation* pada *image* tumor otak. Hasil ekstraksi itu di proses menggunakan metode *meta-heuristic* untuk mendapatkan tingkat *accuracy* yang tinggi dalam memprediksi hasil. Keakuratan klasifikasi dan prediksi yang diperoleh berkisar antara 88,9% hingga 98,8%. Berdasarkan [14], [44], [45] dapat digambarkan bahwa metode *meta-heuristic* dapat digunakan untuk teknik optimasi seperti (*Genetic Algorithm* (GA), *Particle Swarm Optimization* (PSO), *Tabu Search*, *KMN-Tabu*, *Ant colony*, dan *Bee Colony*) yang dapat digunakan untuk mengoptimasi proses tertentu dalam tahapan *deep learning*, yang dimana proses tersebut membutuhkan tingkat keakuratan yang lebih baik lagi.

2.2. Classification Image

Fungsi dari *classification image* selain meminimalisir noise pada sebuah image, *classification image* dapat digunakan untuk mendeteksi keausan pada sebuah permukaan besi tua (Gonzalez-Arias et al., 2019). Dengan menggunakan *classification image* yang di proses menggunakan metode *Histogram of Oriented Gradient* (HOG) dapat memprediksi tingkat keausan permukaan besi tua dengan tingkat akurasi sekitar 80% (Gonzalez-Arias et al., 2019).

2.3. Segmentation Image

Selain *classification image* pada *deep learning* terdapat aplikasi yang namanya *segmentation*. *Segmentation* terdapat dua macam yaitu *segmentation instance* dan *segmentation semantic*. Menurut (Wang et al., 2021) *segmentation semantic* adalah sebuah proses yang menghubungkan setiap pixel gambar ke dalam suatu label kelas. Pada penelitiannya (Wang et al., 2021) *segmentation semantic* digunakan untuk mengenali suatu gambar RGB berdasarkan warna dan fitur. Untuk mengambil gambar RGB ada kesulitan tersendiri yaitu kompleksitasnya struktur warna di gambar RGB. Pada (Wang et al., 2021) dijelaskan juga tentang proses *segmentation semantic* pada gambar 3D.

Segmentasi citra merupakan teknik untuk membagi citra ke dalam beberapa region berdasarkan kemiripan atribut yang dimiliki (Putra, 2010). Terdapat dua karakteristik nilai derajat kecerahan yang terdapat pada segmentasi citra. Dua karakteristik tersebut *discontinuity* dan *similarity*. Citra akan dipisahkan berdasarkan perubahan yang mencolok dari derajat kecerahannya, biasanya citra dideteksi tepi, garis, area dan sisi citra. Pada *similarity*, citra akan dipisah berdasarkan *thresholding*, *region growing*, *spion slitting* dan *merging*. Semua itu akan diterapkan pada citra yang statis dan dinamis (Pangarso and Kusumanigrum, 2019).

2.4. Object Detection

Selain aplikasi *classification* dan *segmentation* yang digunakan pada metode *Convolutional Neural Network* (CNN) untuk mendeteksi gambar terdapat banyak cara salah satunya menggunakan pendekatan model *deep learning Supervised Object Detection* (WSOD) and *Localization* (WSOL) yang menggunakan aplikasi *object detection* (Shao et al., 2022). Pada (Shao et al., 2022) dijelaskan secara teoritis perbandingan dari semua penelitian yang sudah pernah membahas tentang teknik yang digunakan pada WSOD dan WSOL. Pada penelitiannya (Kong et al., 2022) untuk mengetahui tingkat keselamatan suatu kapal laut itu terdapat beberapa kriteria diantaranya adanya hydrant, pelampung, dan jalur

evakuasi. *Object detection* merupakan salah satu teknik aplikasi pada metode *Convolutional Neural Network* (CNN) yang digunakan untuk mendeteksi suatu obyek pada suatu gambar. Pada penelitiannya (Zhang et al., 2021) *object detection* digunakan untuk mendeteksi benda benda asing pada sebuah batu bara dengan mengimplementasikan arsitektur *VGG16* dan *Resnet-Unet*.

Anotasi gambar atau penerjemahan gambar menjadi numerik agar beban dalam *object detection* tidak terlalu berat maka bisa dilakukann dengan otomatis. Pada penelitiannya (Zhang et al., 2022) bahwa untuk melakukan anotasi gambar secara otomatis menggunakan *object detection* dapat dilakukan dengan tiga aspek yaitu 1) strategi pembuatan data sintetis baru, yang dapat secara otomatis menghasilkan data sintetis skala besar dengan anotasi kotak pembatas yang hanya fokus pada kategori target; 2) gabungan paradigma pelatihan diri dengan strategi pembuatan data sintetik, yang digunakan untuk menggali lebih banyak informasi dari data nyata tanpa catatan melalui pelatihan berulang agar dapat meningkatkan kinerja detektor objek; 3) menggunakan metode penyaringan *function* yang sederhana dan efektif, yang tidak merubah kualitas *function* selama pelatihan.

2.5. Artificial Intelligence, Machine Learning dan Deep Learning

Kecerdasan buatan (*Artificial Intelligence*) adalah kecerdasan yang diciptakan manusia untuk mesin, bertujuan untuk menyelesaikan problem yang spesifik di berbagai bidang (Aptikom, 2020). Secara konsep untuk *Artificial Intelligence* sendiri yaitu ilmu yang masih abstrak atau belum jadi sepenuhnya. Berbeda dengan *Machine Learning* yang mempunyai arti yaitu mempelajari algoritma yang ada dan ilmu-ilmu umum lainnya karena di *Machine Learning* itu dibutuhkan operasi hitungan. Perbedaan terakhir ada di *Deep Learning* yaitu suatu komputer dapat mensimulasikan dirinya agar bisa bekerja dan memecahkan suatu permasalahan (Aptikom, 2020).

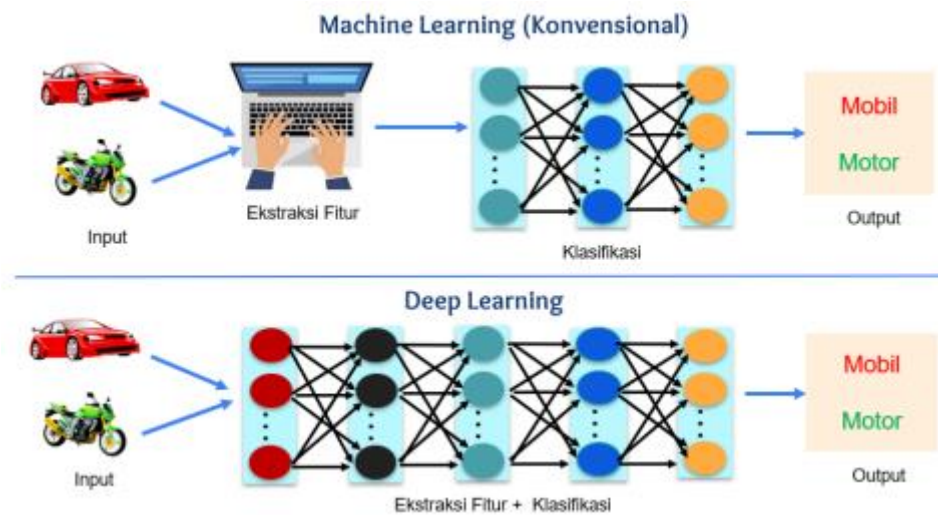
Artificial Intelligence (AI) memiliki beberapa jenis diantaranya adalah *Neural Network* (NN) (Aptikom, 2020). *Neural Network* (NN) adalah pembelajaran mesin yang terinspirasi oleh proses kerja biologis makhluk hidup yaitu neuron dan sistem saraf (Bhisop Christopher M., 1995). Kelebihan *Neural Network* (NN) adalah dapat membaca data input dengan tepat walaupun data tersebut tidak lengkap. Kelebihan tersebut yang tidak bisa diselesaikan dengan model pendekatan komputasi tradisional.

Pada gambar 2.1 yang dapat digambarkan bahwa pendekatan klasifikasi secara *Machine Learning* (konvensional) umumnya melakukan ekstraksi fitur secara terpisah

kemudian dilanjutkan proses pembelajaran menggunakan metode klasifikasi konvensional. Pendekatan konvensional memiliki beberapa kelemahan diantaranya:

- Memerlukan waktu dan pengetahuan lebih untuk ekstraksi fitur.
- Sangat tergantung pada satu domain permasalahan sehingga tidak berlaku general.

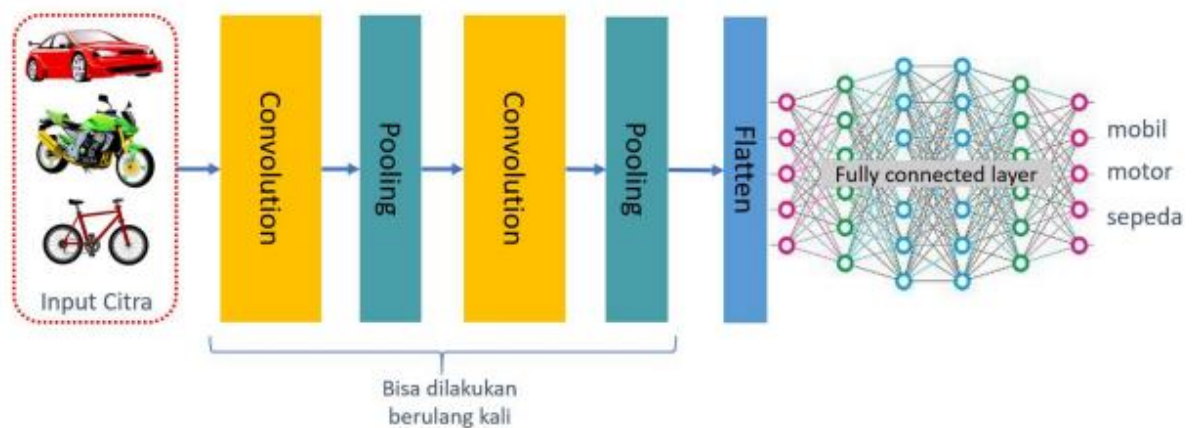
Sedangkan pendekatan klasifikasi berbasis *deep learning* mempelajari representasi hirarki (pola fitur) secara otomatis melalui beberapa tahapan proses *feature learning* (Fatichah, 2021).



Gambar 2.1. Ilustrasi Konsep *Machine Learning* dan *Deep Learning*.


2.6. Metode Convolutional Neural Network (CNN)

Menurut (Putra, 2010) metode *Convolutional Neural Network* (CNN) merupakan salah satu jenis arsitektur dari ANN untuk memproses data yang memiliki susunan topologi seperti *grid*. Menurut *Convolutional Neural Network* (CNN) adalah suatu algoritma *deep learning* yang berbasis *Neural Network* (NN) dan memiliki beberapa proses diantaranya proses *convolution*, proses aktivasi, proses *pooling*, dan proses *fully connected layer* yang semua proses tersebut dengan memanfaatkan layer-layer yang ada ada di *Neural Network* (NN) (Thi Ngo et al., 2021; Wang et al., 2019). Arsitektur *Convolutional Neural Network* (CNN) adalah untuk proses klasifikasi diilustrasikan pada Gambar 2.2.



Gambar 2.2. Arsitektur *Convolutional Neural Network* (CNN)


Tahap pertama merupakan tahap *convolution*, ilustrasi proses *convolution* dapat dilihat pada Gambar 2.3. Pada tahap ini, melakukan operasi *convolution* pada data input dengan kernel. Kernel pada CNN merupakan array multidimensional yang menjadi operator untuk melakukan operasi tertentu dengan array input. Nilai yang terdapat pada kernel merupakan nilai yang diperoleh dari hasil learning. Hasil operasi aljabar antara input dengan kernel disebut dengan *feature map*. Proses operasi antara input dengan kernel ini disebut dengan proses ekstraksi fitur ke dalam *feature map*. Contoh proses *convolution* pada sebuah citra dapat dilihat pada Gambar 2.3.



Gambar 2.3. Proses *Convolution* Pada Citra

Tahap kedua merupakan tahap detector yaitu hasil dari tahap sebelumnya dijadikan sebagai input ke dalam suatu fungsi aktivasi misalnya *Rectified linear unit* (ReLU). Tahap ketiga merupakan tahap *pooling* yaitu mereduksi dimensi dari input array yang masuk dengan memanfaatkan fungsi maksimum, penjumlahan, atau rata-rata, yang disebut *maxpooling*, *sum-pooling*, atau *average-pooling*. Output dari tahapan ini menghasilkan

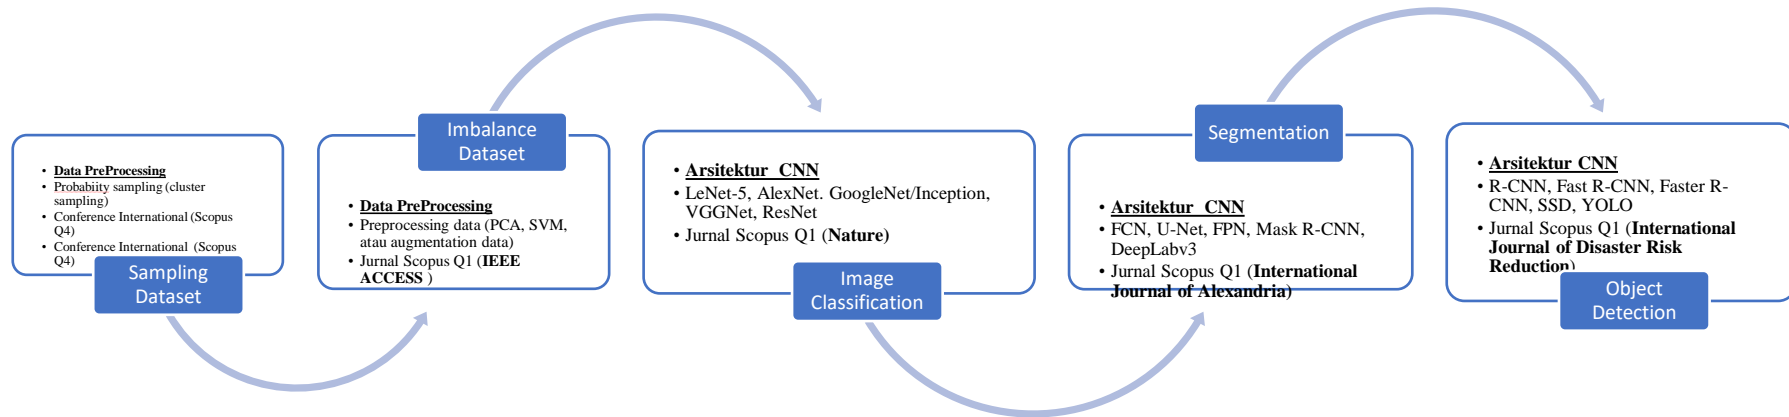
dimensi data menjadi lebih kecil namun tanpa menghilangkan informasi penting dari data yang diterima. Pooling layer yang umum digunakan untuk mengurangi ukuran gambar menjadi lebih kecil (downsample) dan mengekstrak salient features adalah *Maximum Pooling* dan *Average Pooling*. Ilustrasi konsep dari *Max Pooling* dan *Average Pooling* dapat dilihat pada Gambar 2.4.



Gambar 2.4. Ilustrasi konsep dari *Max Pooling* dan *Average Pooling*

Setelah menggunakan beberapa *convolutional* dan *pooling* layer, umumnya untuk permasalahan klasifikasi digunakan layer tambahan berupa *fully connected layer* sebagai tahap 4 yang melakukan proses flattening dari matriks menjadi sebuah vektor, dan selanjutnya digunakan untuk melakukan klasifikasi.

2.7. Roadmap Penelitian



Gambar 2.5. Roadmap Penelitian

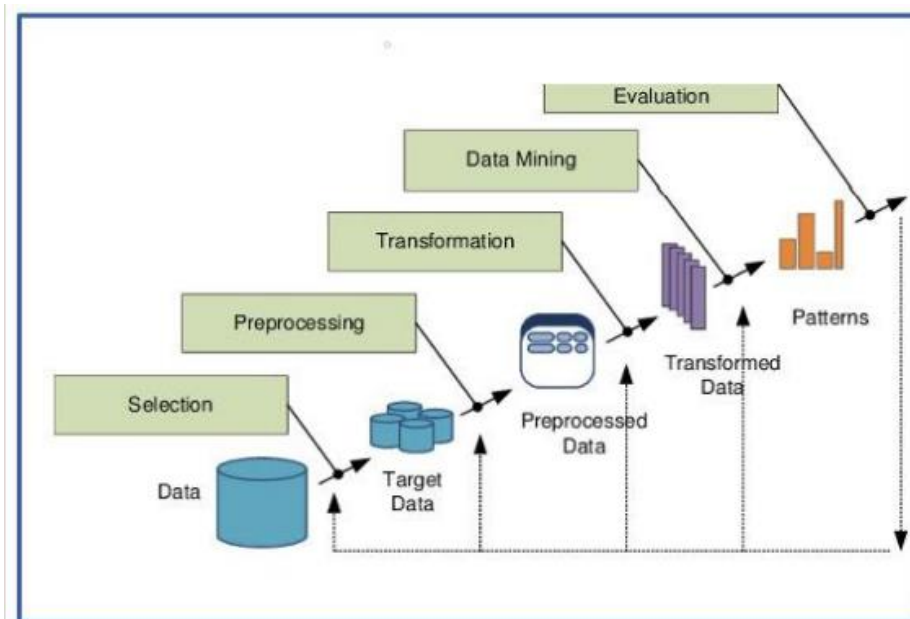
BAB III

METODOLOGI PENELITIAN

Secara umum metodologi untuk *data science* ada 2 kelompok metodologi yaitu metodologi teknis dan metodologi bisnis.

3.1. Metodologi Teknis

Metodologi teknis dimulai dari adanya data yang diproses untuk mendapatkan suatu pola yang berguna. Terdapat dua jenis metodologi teknis pada data science diantaranya adalah metodologi *Knowledge Discovery and data Mining* (KDD) dan Metodologi SEMMA. Pada penelitian ini menerapkan metodologi teknis KDD, karena proses metodologi KDD sama dengan proses dalam menentukan tingkat kerusakan sektor pasca bencana alam menggunakan citra digital berbasis deep learning. Untuk alur proses metodologi KDD dapat dilihat pada gambar 3.1.



Gambar 3.1. Alur Metodologi *Knowledge Discovery and Data Mining* (KDD)

Berdasarkan gambar 3.1 metodologi KDD adalah proses pemanfaatan metoda Data Mining untuk mengekstraksi pengetahuan sesuai dengan threshold yang sudah ditentukan. Proses dimulai dengan adanya sekumpulan data (*dataset*) yang akan mengalami serangkaian proses sebagai berikut:

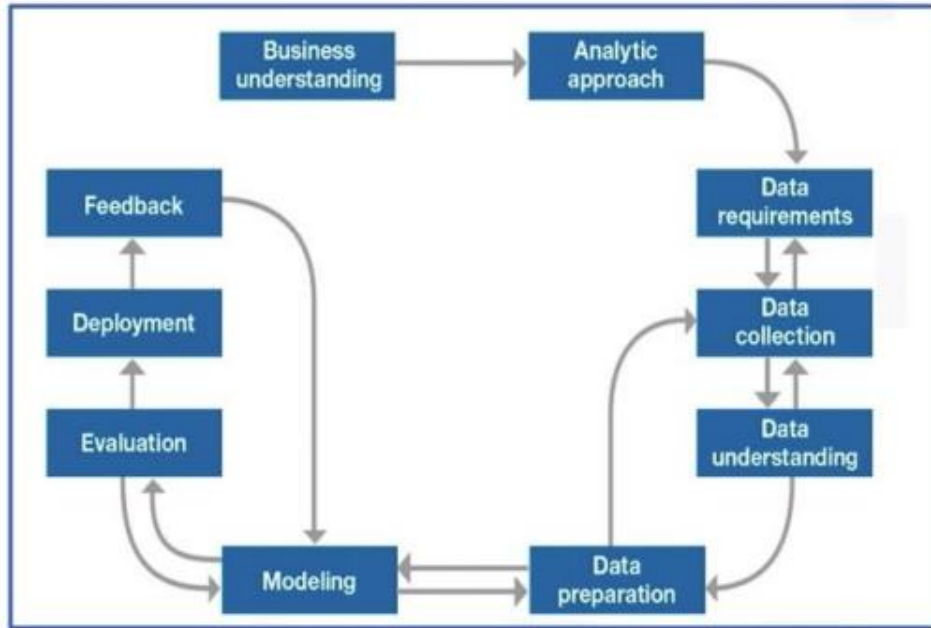
- **Selection:** Pemilihan data (data target) yang akan menjadi sampel untuk proses selanjutnya. Data target yang digunakan merupakan data gambar digital kerusakan

sektor pasca bencana alam yang didapat dari *google/kaggle* atau di foto langsung di lapangan.

- **Preprocessing data:** Melakukan serangkaian proses untuk melengkapi data dan menjaga konsistensi data. Untuk mendapatkan validasi data yang bagus maka perlu data di preprocessing terlebih dahulu, seperti perlu dilakukan seleksi fitur data (*SVM/PCA*), probability sampling (*Cluster Sampling*), imbalance dataset (*oversampling SMOTE* menggunakan *K-Nearest Neighbor*).
- **Transformation:** Mengubah representasi data untuk mempermudah dan memperbaiki agar sesuai dengan teknik data mining yang akan dipergunakan. Terdapat dua cara untuk melakukan data transformation yaitu representasi fitur dan rekayasa fitur. Untuk rekayasa fitur ada beberapa operasi yang akan dilakukan yaitu *imputation, encoding, scaling, handling outliers, log transform, grouping operations, binning*.
- **Data Mining:** Kegiatan pengembangan model untuk mencari pola dari data yang diberikan. Pada saat proses data mining langkah pertama yang dilakukan yaitu merancang skenario eksperimen yang meliputi pembagian data, pemilihan parameter, dan parameter evaluasi. Langkah kedua yaitu melakukan klasifikasi yang meliputi (penerapan metode klasifikasi, pembangunan matrix performansi klasifikasi, dan membangun model berdasarkan studi kasus)
- **Evaluation:** Proses interpretasi dan evaluasi pola yang diperoleh apakah pola yang menarik, berguna atau relevan. Untuk merepresentasikan evaluasi dari hasil dapat menggunakan model *confusion matrix (Precision, Recall, F1-Score, Accuracy)*. Karena menerapkan pemodelan data mining classification maka untuk evaluasi hasil lebih cocok menggunakan mode evaluasi confusion matrix., selain itu dengan menggunakan *Confusion Matrix* dapat direpresentasikan hasil prediksi dengan kondisi sesungguhnya berdasarkan data yang dihasilkan dari training.

3.2. Metodologi Bisnis

Terdapat banyak metodologi bisnis yang digunakan dalam kegiatan data science diantaranya adalah metodologi *CRISP-DM*, Metodologi *IBM Data Science*, Metodologi *Data science Life Cycle* dari *Microsof*, dan *Metodologi Data science Life Cycle* dari *Microsof* (Faticah, 2021). Untuk metodologi bisnis menggunakan metodologi *IBM Data Science*, karena alur kegiatan *data science* pada metodologi bisnis *IBM Data Science* sama dengan kegiatan yang dilakukan dalam penelitian. Untuk alur proses metodologi bisnis *IBM Data Science* dapat dilihat pada gambar 3.2.



Gambar 3.2. Alur Proses Metodologi IBM Data Science

Pada gambar 3.2. alur proses metodologi data science dari IBM diawali dengan kegiatan *Business Understanding* yang merupakan proses pemahaman terhadap masalah yang akan diselesaikan. Di dalam kegiatan tersebut juga dilakukan proses pemetaan antara masalah bisnis dengan tugas analitik (tugas data science yang sesuai).

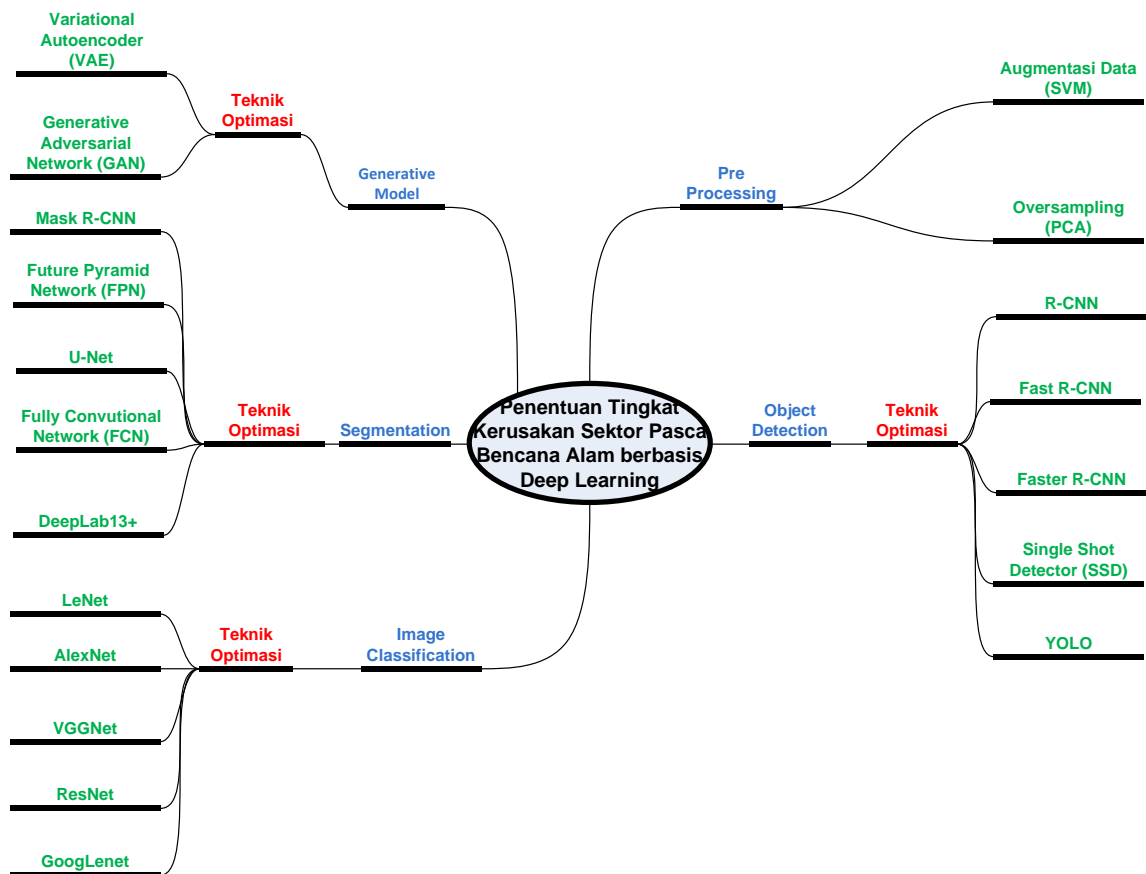
3.3. Kerangka Pikir

Penentuan tingkat kerusakan sektor pasca bencana alam yang selama ini dilakukan oleh surveyor masih menggunakan pengetahuan dari para surveyor. Pengetahuan surveyor yang berbeda-beda menyebabkan hasil yang ditentukan juga berbeda. Perbedaan itu menyebabkan suatu problem yang besar di pemerintah yaitu tentang bantuan yang akan disalurkan oleh pemerintah untuk ganti rugi kerusakan sektor pasca bencana alam. Bantuan yang disalurkan terhadap masyarakat yang sektor kehidupannya terdampak bencana berbeda dengan dengan kondisi di nyata sektor di lapangan. Hal itu yang mendasari perlu sebuah teknologi yang dapat menentukan tingkat kerusakan sektor pasca bencana alam menggunakan dengan standart yang sama dan memiliki kecerdasan yang otomatis tanpa adanya perbedaan pengetahuan. Teknologi tersebut adalah *Artificial Intelligent* (Kecerdasan Buatan).

Pada *Artificial Intelligent* memiliki beberapa jenis metode salah satunya adalah metode *Neural Network*. Dengan perkembangan jaman metode *Neural Network* berkembang dengan menerapkan konsep bahwa metode *Neural Network* dapat menyelesaikan suatu problem hanya dengan melibatkan manusia pada satu langkah saja dari beberapa langkah

pengerjaan di metode *Neural Network*, yaitu melakukan ekstrak fitur data sedangkan untuk input, proses dan hasil dapat dilakukan oleh metode *Neural Network*. Proses tersebut lebih dikenal dengan istilah *Machine Learning*. Dalam *Machine Learning* masih memiliki kekurangan yaitu keterlibatan *human* (manusia) dalam proses pengolahan datanya untuk mencapai hasil yang diharapkan. Seperti pada gambar 2.1 jika manusia masih terlibat dalam proses *Machine Learning*, yang menyebabkan butuh waktu yang lama dan domain atau problem tertentu saja yang bisa diselesaikan oleh *Machine Learning*. Dengan adanya kelemahan dari *Machine Learning* tersebut maka muncul metode baru yaitu *Deep Learning*. *Deep Learning* merupakan bagian dari *Artificial Intelligent* yang fokus menyelesaikan problem pengolahan citra digital dengan data yang banyak dan membutuhkan hasil yang handal. Metode yang digunakan pada *Deep Learning* yaitu *Convolutional Neural Network* (CNN). CNN merupakan pengembangan dari *Neural Network* yang menggunakan lapisan *convolutional* dan *pooling* yang berlipat-lipat dalam membaca suatu obyek dengan mengambil sebagian kecil dari obyek tersebut untuk diidentifikasi obyeknya agar sesuai dengan aslinya. CNN sendiri memiliki 4 aplikasi yaitu *Classification Image*, *Segmentation*, *Object Detection*, dan *Generative Model*. Masing-masing aplikasi memiliki arsitektur sendiri-sendiri.

Berdasarkan keterangan diatas maka akan diteliti bagaimana menentukan tingkat kerusakan sektor pasca bencana alam dengan menerapkan 4 aplikasi yang ada di CNN yang kemudian akan di proses menggunakan arsitektur-arsitektur berdasarkan aplikasi dari CNN. Untuk penentuan arsitektur pada setiap aplikasi akan menggunakan teknik optimasi agar mendapatkan arsitektur CNN yang cocok dan tepat terhubung dengan metode CNN. Selain akan membahas tentang proses metode CNN, juga akan membahas *pre-processing* data. *Pre-processing* data akan menggunakan 2 metode yaitu metode *Support Vector Machine* (SVM) dan *Principal Critical Analysis* (PCA). Untuk metode SVM digunakan untuk memberi label pada setiap data berdasarkan tingkat kerusakan sektor pasca bencana dan digunakan untuk membagi data berdasarkan kriteria kerusakan sektor pasca bencana alam. Sedangkan metode *Principal Critical Analysis* (PCA) digunakan untuk clustering jenis tingkat kerusakan sektor pasca bencana alam, selain itu PCA digunakan juga untuk kompresi data citra digital agar data yang digunakan tidak berat tapi tidak mengurangi informasi yang ada pada data tersebut. Untuk *mind mapping* penelitian dapat dilihat pada gambar 3.3.



Gambar 3.3. *Mind Mapping* Penelitian

3.4. Waktu dan Tempat

1. Waktu Penelitian

Kurang lebih selama 1 tahun waktu yang digunakan peneliti dalam melakukan penelitian ini dengan rincian sebagai berikut: 2 bulan pertama melakukan kajian literatur penyusunan proposal penelitian, 2 bulan kedua melakukan ujian kelayakan dan seminar proposal penelitian, 4 bulan ketiga proses penelitian, 4 bulan ke empat melakukan publikasi Jurnal International terindex Scopus Q1.

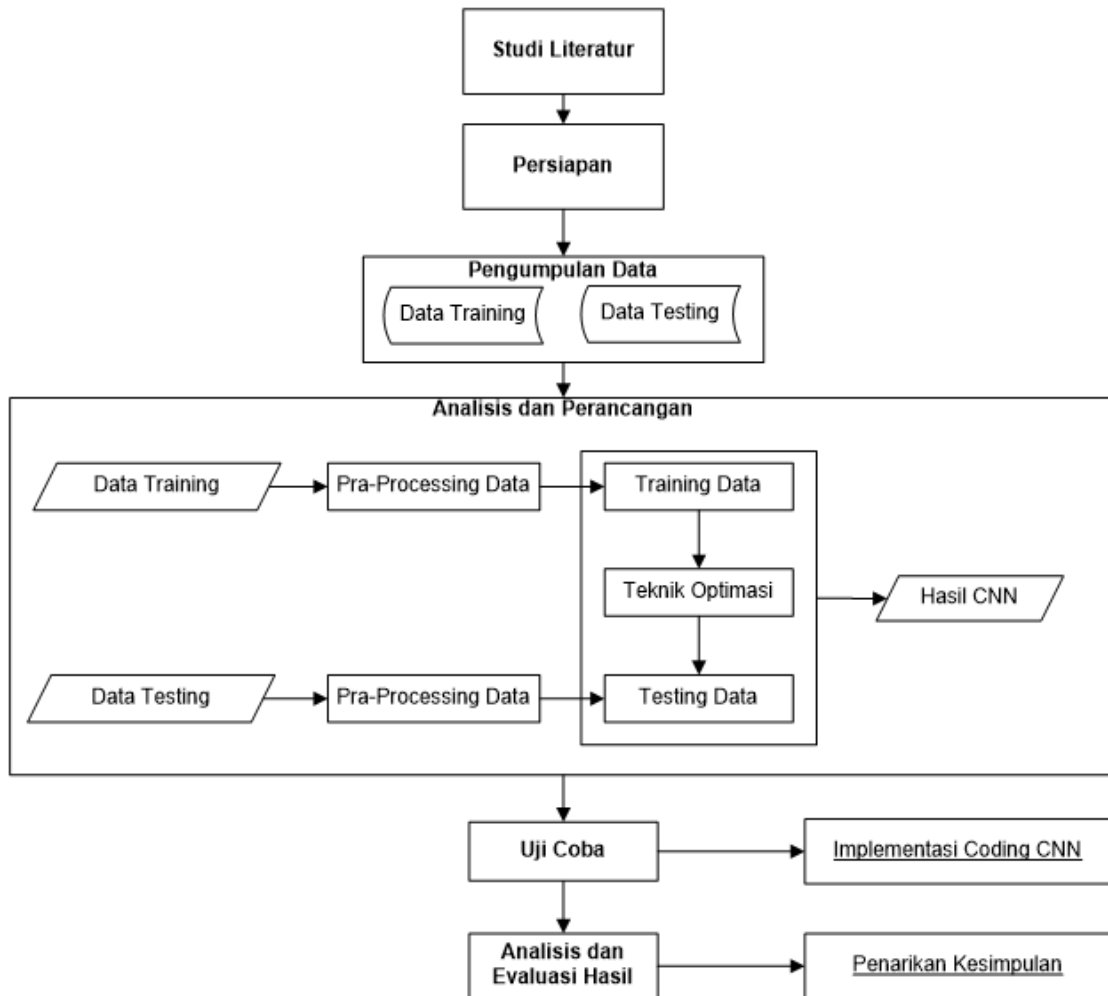
2. Tempat Penelitian

Tempat penelitian dilakukan di Provinsi Jawa Timur. Tepatnya di Kawasan Kampus 3 UIN Maulana Malik Ibrahim Malang di Kota Batu dan sekitarnya. Tetapi secara global dapat menggunakan data dari daerah mana pun.

3.5. Prosedur Penelitian

Terdapat beberapa tahapan yang digunakan pada penelitian ini diantaranya adalah studi literatur, pengumpulan data, analisis perancangan, implementasi, uji coba, analisis

evaluasi hasil, uji coba, dan penarikan kesimpulan. Pada gambar 3.4. dapat dilihat alur dari penelitian yang akan dilakukan.



Gambar 3.4. Rancangan Penelitian

3.5.1. Studi Literatur

Pencarian sumber referensi yang terkait dilakukan untuk membuat *study literature* yang tepat dan sesuai dengan penelitian. *study literature* yang dicari mengenai konsep *image processing*, *pre-processing data*, *classification image*, *segmentation*, *object detection*, arsitektur *Convolutional Neural Network* (CNN), retak (*crack*) bangunan, teknik optimasi, dan teknik evaluasi arsitektur CNN. Hasil dari *study literature* yang sudah dilakukan adalah suatu rumusan langkah yang akan dikerjakan, dan terdapat sesuatu *novelty* yang akan dilakukan pada penelitian ini.

3.5.2. Persiapan

Pengumpulan data menggunakan 2 cara yaitu *online* dan *offline*. Untuk cara *online* dengan mencari data dari situs yang menyediakan data yaitu *Google* dan *Kaggle*. *Data online*

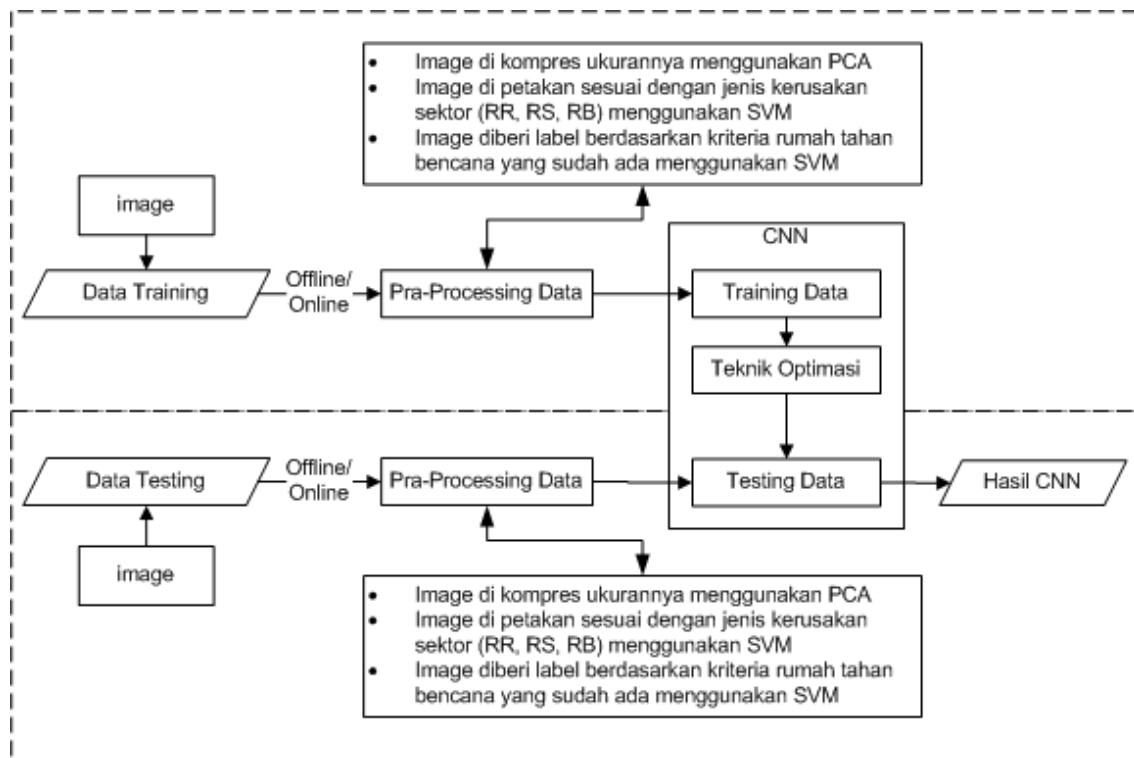
dipilih karena data tersebut sudah tervalidasi jadi jika digunakan penelitian sudah jelas dan valid. Sedangkan data *offline* merupakan data hasil dari survey lapangan. Kelemahan data survey adalah data tersebut belum valid jadi perlu adanya validasi dari stakeholder (BPBD, PU atau Pemda) yang menjadi tempat survey.

3.5.3. Pengumpulan Data

Langkah pertama pada saat pengumpulan data adalah membagi data tersebut. Pembagian data dapat menggunakan dua cara yaitu *train-validation split* dan *k-fold cross validation*. Pembagian data model *train-validation* merupakan pembagian data dengan membagi jumlah data menjadi 3 yaitu data latih, data validasi, dan data uji. Pembagian data model *train-validation* dapat membantu risiko *underfitting* dan *overfitting* yang sering ditemui oleh nilai hyperparameter yang kurang baik. Selain itu juga dapat digunakan untuk indikator baik dan buruknya mode prediktif dalam menyelesaikan masalah tertentu. Sedangkan *k-fold cross validation* sering digunakan untuk dataset yang tidak terlalu besar.

3.5.4. Analisis dan Perancangan

Pada langkah ini yang dilakukan adalah menganalisis *requirement* system secara intensif dan spesifik. Terdapat beberapa komponen untuk hal yang perlu dipahami diantaranya memahami domain informasi, *function* yang dibutuhkan, kinerja, perilaku, dan *interface* yang dibutuhkan. Untuk alur analisis dan perancangan terdapat gambar 3.5.



Gambar 3.5. Analisis dan Perancangan

3.5.5. Pra-Processing Data

Pada pra-processing data, akan melakukan proses kompresi image yang awalnya foto asli atau image asli akan di kompres agar ukurannya lebih kecil tapi tetap terbaca value dari image tersebut. Proses kompresi image dilakukan karena proses *Convolutional Neural Network* (CNN) menggunakan ukuran image yang sama semuanya. Kemudian langkah selanjutnya adalah proses *thresholding* yaitu merubah image yang RGB menjadi hitam putih (grayscale). Hasil dari *thresholding* kemudian merubah ukuran image menjadi 28x28 pixel karena ukuran tersebut merupakan ukuran default image di model CNN. Selain melakukan kompresi image yaitu *clustering* data agar mengetahui labeling dari masing-masing data dengan menggunakan *Principal Component Analysis* (PCA).

BAB IV

HASIL DAN PEMBAHASAN

Pada bab ini akan dijelaskan mengenai hasil dan pembahasan tentang penelitian Decision Support System Untuk Clustering Tingkat Kerusakan Bangunan Pasca Bencana Alam Menggunakan Deep Learning.

4.1. Pelaksanaa Penelitian

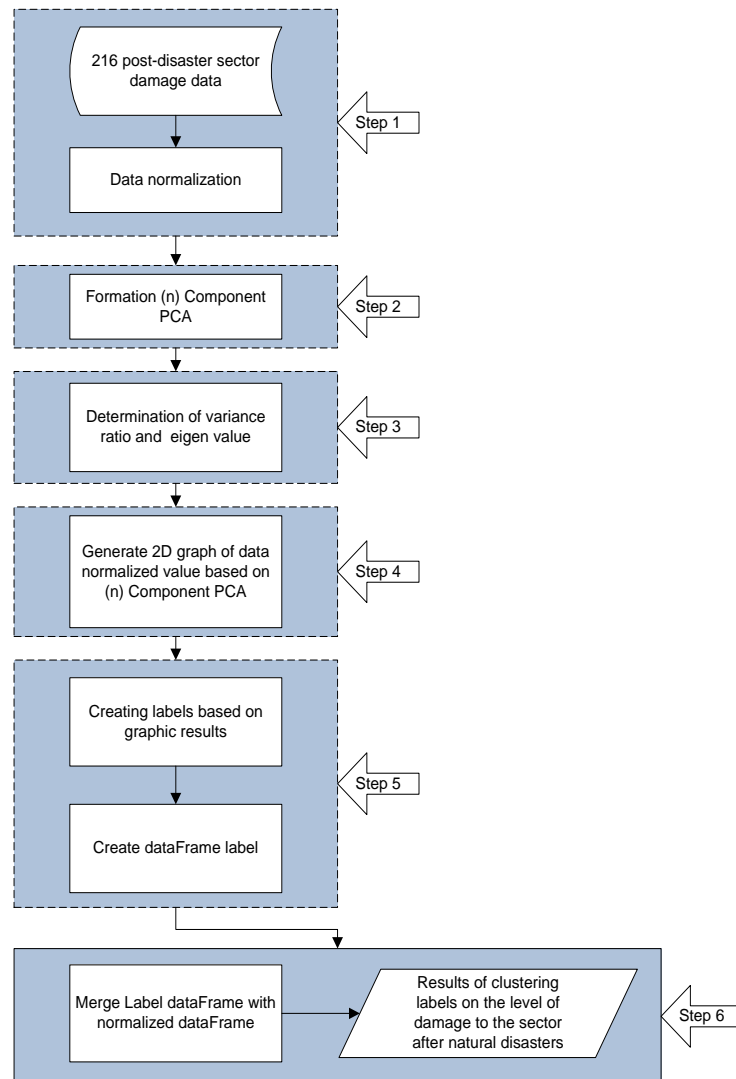
Penelitian kami lakukan pada tiga tempat karena melibatkan 3 Perguruan Tinggi yaitu UIN Maulana Malik Ibrahim Malang, Universitas Brawijaya Malang, dan Constructor University Germany. Setiap Perguruan Tinggi memiliki tugas dan fungsi masing-masing terkait dari penelitian ini. Untuk UIN Maulana Malik Ibrahim Malang terlibat dalam hal tempat penelitian (Laboratorium Database Jurusan Teknik Informatika), sedangkan Universitas Brawijaya Malang terlibat dalam hal tempat diskusi dalam memecahkan masalah dan mencari solusi untuk mencapai outcome dari penelitian kami ini, dan untuk Constructor University Germany merupakan mitra dari penelitian kami yang melibatkan salah satu Profesor dari Constructor University Germany yaitu Prof. Dr-Eng Hendro Wicaksono.

4.2. Hasil Road Map Penelitian

Berdasarkan mind mapping penelitian pada gambar 3.3. dapat menghasilkan beberapa pembahasan dan penemuan yaitu:

1. Labeling data menggunakan Principal Component Analysis (PCA).

Berikut merupakan Langkah-langkah labelling menggunakan PCA:



Gambar 4.1. Arsitektur Labelling menggunakan PCA

Menggunakan PCA untuk clustering data kerusakan sektor pasca bencana alam kemudian hasil clustering tersebut menghasilkan lebl data menurut rang nilai hasil dari PCA. Pada gambar 4.1 dapat dilihat bahwa setelah membuat grafik 2D data dari nilai yang sudah dinormalisasi berdasarkan (n) komponen PCA, kemudian membuat label dari grafik pada gambar 4.1 dan membuat dataframe dari label yang sudah berhasil dibuat. Langkah-langkah PCA yang digunakan sebagai berikut:

Langkah 1: Menyiapkan data.

Menggunakan data hasil dari para surveyor dalam melakukan penilaian tingkat kerusakan sector pasca bencana yang terjadi di Provinsi Jawa Timur Indonesia. Data kerusakan bangunan atau sector pasca bencana alam yang digunakan merupakan suatu data yang sudah berupa hasil analisis dari data para surveyor tersebut yang berjumlah sebanyak 216 data.

Langkah 2: Melakukan normalisasi data.

Proses normalisasi merupakan salah proses untuk menjadikan data menjadi standart agar sesuai dengan standart dari PCA. Menurut *Susilo et al* standart data PCA adalah data yang digunakan harus memiliki derajat atau value yang sama dan seimbang dari setiap data (Susilo et al., 2020). Pada penelitiannya (Ahsan et al., 2021) terdapat 6 metode untuk menstandartkan data yaitu Normalization (NR), Standartscale (SS), MinMax (MM), MaxAbs (MA), Robust Scale (RS), dan Quantile Transformer (QT). Pada penelitian ini menggunakan Standartscale (SS) karena jenis data kerusakan bangunan pasca bencana alam menggunakan standart skala yaitu 1/2/3. Persamaan dari Standartscale (SS) menggunakan persamaan berikut (Smith, 2002):

$$x_{standart} = \frac{x - \text{mean}(x)}{\text{standart deviation}(x)} \quad (4.1)$$

Standart deviasi menggunakan persamaan dari (Smith, 2002) sebagai berikut:

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} \quad (4.2)$$

Simbol \bar{X} (X bar) menggambarkan tentang nilai rata-rata dari himpunan X.

Langkah 3: Menentukan nilai variance ratio dan eigen value.

Variance ratio merupakan ukuran untuk persebaran suatu data. Persamaan untuk menentukan variance ratio dapat menggunakan persamaan berikut:

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{(n-1)} \quad (4.3)$$

Persamaan (3) memiliki pengertian bahwa persebaran suatu data memiliki ukuran tertentu yang dapat menentukan jumlah persebaran data.

Sedangkan eigen value merupakan suatu nilai yang menempati suatu tempat pada eigen vector yang berbentuk suatu matrix (Smith, 2002).

Langkah 4: Menentukan jumlah komponen utama (PC).

Pada penelitiannya (Gu, 2020) menjelaskan bahwa untuk menentukan jumlah komponen utama pada PCA merupakan proses yang sangat penting karena dapat mempengaruhi tingkat akurasi dari suatu kumpulan data. Selain itu menentukan jumlah komponen utama yang tepat maka akan mendapatkan nilai *eigen value* dan *variance ratio* yang paling optimal (Iswan and Garniwa, 2017).

Langkah 5: Membuat visualisasi.

Visualisasi merupakan suatu hal yang sangat penting dalam merepresentasikan suatu hasil (Kai et al., 2021) terutama pada hasil PCA. Dengan menggunakan

grafik 3 dimensi (3D) untuk merepresentasikan menjadi sebuah range nilai yang hasilnya menggambarkan hasil pada gambar 2 dimensi (2D).

Langkah 6: Membuat range nilai.

Menurut *Lambers et al.* range nilai dapat dilakukan dengan memaksimalkan nilai tertinggi dalam suatu kumpulan data dan meminimalkan kehilangan informasi yang disebabkan oleh reduksi data (Lambers et al., 2008). Pada penelitian kami ini untuk membuat range nilai menggunakan hasil dari PC.

Langkah 7: Clustering data.

Clustering merupakan suatu teknik pembelajaran membagi data menjadi beberapa bagian data unsupervised ke dalam sejumlah kelompok data yang homogen (Huang et al., 2021; Wu et al., 2018). Pada penelitian kami untuk clustering data menggunakan data titik koordinat hasil PC berdasarkan range nilai yang sudah ditentukan. Hasil clustering data membutuhkan validation agar dapat diketahui tingkat kebenarannya.

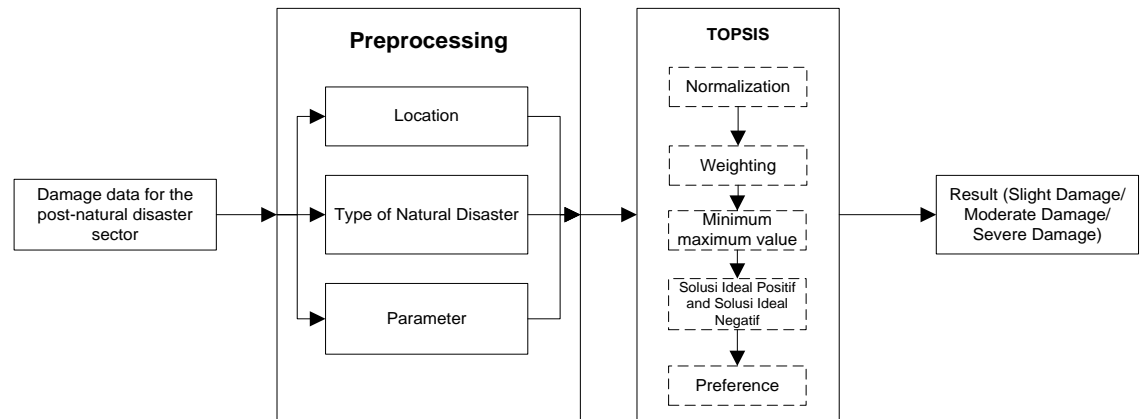
Langkah 8: Result dan Validation.

Result merupakan suatu nilai yang sudah melewati suatu proses tertentu, sedangkan untuk mengetahui tingkat kebenaran suatu hasil perlu melakukan suatu validation (Huang et al., 2022; Thabet et al., 2021). Validation merupakan peran kunci dalam menentukan apakah hasil yang sudah di dapatkan sesuai dengan persyaratan yang sudah ada (Basile and Ferrara, 2023). *Byabazaire et al.* menjelaskan bahwa validasi hasil dapat dilakukan dengan menguji dua data yang berbeda yaitu data trust matric dengan model building dengan mengkorelasikan dua data tersebut agar mendapatkan nilai eror yang paling kecil (Byabazaire et al., 2022). Berikut merupakan langkah-langkah untuk validasi hasil:

- Memvisualisasikan 2 dimensi dan 3 dimensi data hasil PCA yaitu data PC1 dan PC2.
- Memvisualisasikan 2 dimensi hasil data target asli yang sudah melewati validasi surveyor.
- Memvisualisasikan 2 dimensi hasil PC1 dengan data target asli.
- Memvisualisasikan 2 dimensi hasil PC2 dengan data target asli.
- Membandingkan hasil visualisasi 2 dimensi dari PC1 berdasarkan data target asli dengan PC2 berdasarkan target asli.

2. SDDS: Sistem Penentuan Level Kerusakan Sektor Pasca Bencana Alam Berbasis Karakteristik Bangunan.

Berikut Langkah-langkah SDDS:



Gambar 4.2. Arsitektur SDDS

Data yang dihasilkan pada proses preprocessing data berupa lokasi, jenis bencana alam, dan parameter. Kemudian data tersebut memasuki tahapan dari komputasi metode TOPSIS yaitu normalisasi, pembobotan, nilai maximum minimum, solusi ideal positif (A^+) dan solusi ideal negatif (A^-), dan nilai preferensi. Setelah melalui tahapan komputasi metode TOPSIS maka langkah selanjutnya adalah hasil (Rusak Ringan/ Rusak Sedang/ Rusak Berat). Metode *Technique for Order Preference by Similarity to Ideal Solution*, atau yang biasa disebut sebagai metode TOPSIS, adalah salah satu dari sekian metode yang bisa diterapkan pada sebuah sistem pendukung keputusan. Metode TOPSIS termasuk salah satu metode dasar dari *Multiple Criteria Decision Making*, atau yang biasa disingkat menjadi MCDM, yang banyak diimplementasikan karena kesederhanaan dan kemudahan penerapannya bahkan untuk kasus yang memiliki banyak kriteria dan alternatif sekalipun, serta konsep yang mendasarinya, dimana solusi terbaik merupakan solusi yang berposisi paling dekat dari solusi ideal positif juga berposisi paling jauh dari solusi ideal negatif (Çelikkilek and Tüysüz, 2020). Metode TOPSIS telah banyak digunakan dalam berbagai bidang sebagai metode penentuan keputusan, seperti dalam perbandingan kinerja perusahaan, penilaian kualitas layanan, sistem manufaktur, dan sebagainya (Ren et al., 2010). Bahkan menurut penelitian yang dilakukan, metode TOPSIS merupakan metode MCDM kedua yang paling banyak digunakan, setelah metode *Analytic Hierarchy Process* (AHP) (Zyoud and Fuchs-Hanusch, 2017).

Komputasi metode TOPSIS dapat dijabarkan menjadi beberapa tahapan perhitungan sebagai berikut (Bagi et al., 2020; Chakraborty, 2022; Safitri et al., 2022):

- a. Menghitung matriks keputusan yang ternormalisasi.

Rating kinerja atau yang juga dikenal sebagai matriks keputusan merupakan preferensi untuk setiap alternatif terhadap kriteria. Normalisasi dilakukan pada matriks keputusan awal (matriks X) untuk menjadikan perbandingan antar kriteria menjadi lebih mudah. Matriks yang ternormalisasi (matriks Y) dapat dihitung menggunakan persamaan (4.4).

$$y_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^I x_{ij}^2}} \quad (4.4)$$

- b. Mengintegrasikan bobot dengan rating.

Matriks keputusan terbobot dan ternormalisasi v_{ij} dihitung menggunakan persamaan (4.5). yang kemudian membentuk matriks V , dimana W menunjukkan atribut bobot.

$$v_{ij} = W_j * y_{ij};$$

$$(i = 1, 2, \dots, I; j = 1, 2, \dots, J) \quad (4.5)$$

- c. Menentukan nilai maximum dan minimum.

Nilai maksimum dan minimum dari setiap kriteria ditentukan untuk menghitung tingkat kepentingan relatif dari setiap parameter. Nilai maksimum adalah kemungkinan hasil terbaik untuk kriteria tertentu, sedangkan nilai minimum adalah kemungkinan hasil terburuk. Kepentingan relatif dari setiap parameter kemudian dihitung dengan mengurangkan nilai minimum dari nilai maksimum dan membagi hasilnya dengan selisih antara nilai maksimum dan minimum. Perhitungan ini kemudian digunakan untuk memberikan skor pada setiap opsi berdasarkan seberapa dekat pertemuannya. Nilai maximum dan minimum yang dinotasikan A^+ dan A^- yang bisa didapatkan melalui persamaan (4.6) dan (4.7).

$$A^+ = [v_1^+, v_2^+, \dots, v_j^+] \quad (4.6)$$

$$A^- = [v_1^-, v_2^-, \dots, v_j^-] \quad (4.7)$$

dimana,

$$v_j^+ = \begin{cases} \max v_{ij}, & \text{jika } j \text{ merupakan atribut benefit} \\ \min v_{ij}, & \text{jika } j \text{ merupakan atribut cost} \end{cases}$$

$$v_j^- = \begin{cases} \min v_{ij}, & \text{jika } j \text{ merupakan atribut benefit} \\ \max v_{ij}, & \text{jika } j \text{ merupakan atribut cost} \end{cases}$$

d. Memperoleh nilai solusi ideal positif dan negatif.

Solusi ideal positif adalah kemungkinan hasil terbaik untuk kriteria tertentu, sedangkan solusi ideal negatif adalah kemungkinan hasil terburuk. Solusi ideal positif digunakan untuk menghitung kepentingan relatif setiap parameter, sedangkan solusi ideal negatif digunakan untuk menghitung kepentingan relatif setiap parameter dengan arah berlawanan. Kepentingan relatif dari setiap parameter kemudian digunakan untuk menetapkan skor pada setiap pilihan berdasarkan seberapa dekat pilihan tersebut memenuhi solusi ideal positif atau negatif. Nilai solusi ideal positif (S^+) dan negatif (S^-) merupakan suatu nilai yang bisa didapatkan melalui persamaan (4.8) untuk S^+ dan persamaan (4.9) untuk S^- .

$$S_j^+ = \sqrt{\sum_{j=1}^J (v_{ij} - v_j^+)^2} \quad (4.8)$$

$$S_j^- = \sqrt{\sum_{j=1}^J (v_{ij} - v_j^-)^2} \quad (4.9)$$

e. Menghitung keseluruhan nilai preferensi.

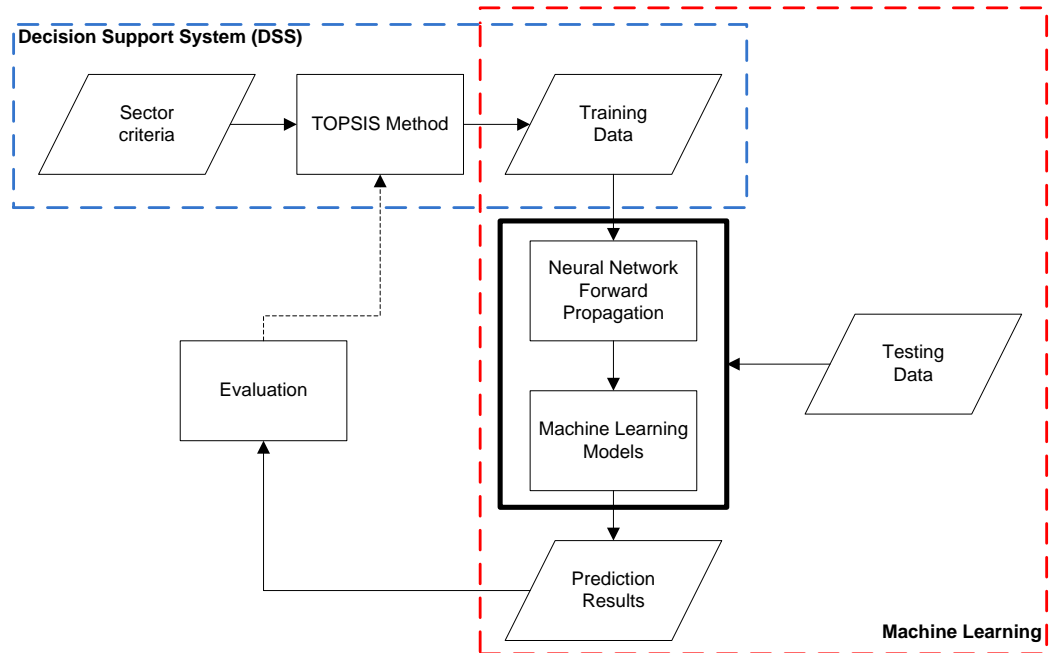
Keseluruhan nilai preferensi yang dinotasikan dalam V_i untuk setiap alternatif dihitung menggunakan persamaan (4.10), dimana alternatif akan di-rating berdasarkan nilai V_i yang lebih tinggi.

$$V_i = \frac{s_i^-}{s_i^- - s_i^+} \quad (4.10)$$

3. SASSD: A Smart Assessment System for Sectoral Damage After Natural Disasters Using Artificial Neural Networks.

SASSD merupakan sistem cerdas yang dapat menentukan tingkat kerusakan sektor pasca bencana alam dengan memanfaatkan data hasil dari decision support system. Data hasil dari proses decision support system yang ada pada penelitian (Bachriwindi et al., 2019) dapat digunakan sebagai data training pada penelitian kami ini. Agar surveyor dalam menentukan tingkat kerusakan sector pasca bencana alam tidak melalui tahapan-tahapan yang ada pada metode MCDM.

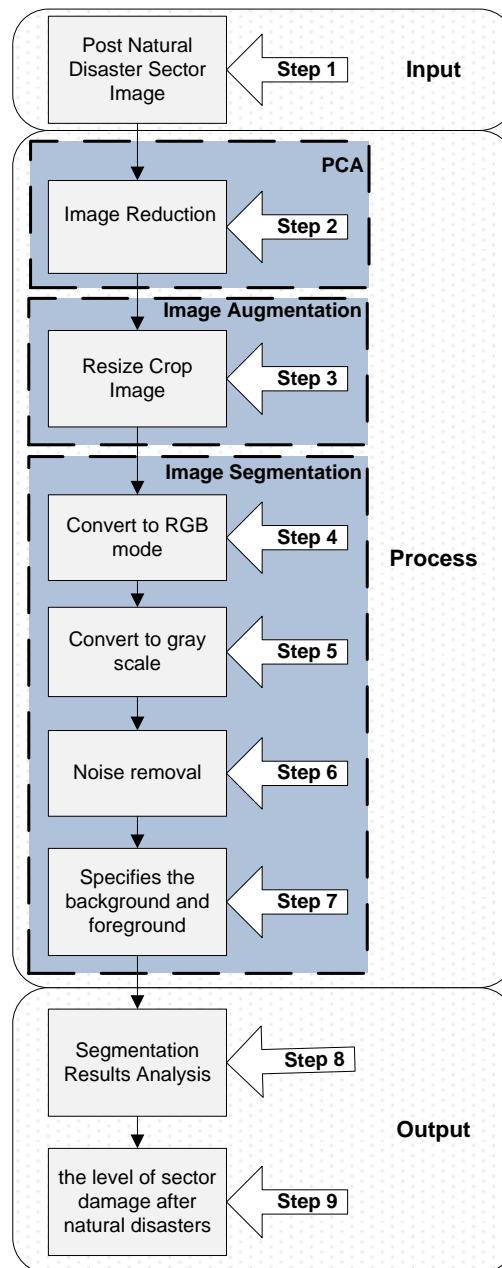
Dengan mengimplementasikan machine learning dalam menentukan tingkat kerusakan sector pasca bencana alam, dapat memudahkan surveyor karena hanya data nilai kriteria sudah mampu menentukan tingkat kerusakan sector pasca bencana alam. Gambar 4.3. menjelaskan tahapan-tahapan dari SASSD yang menggunakan ML dengan algoritma Neural Network Fordward Propagation untuk menentukan tingkat kerusakan sector pasca bencana alam.



Gambar 4.3. Arsitektur SASSD

4. Watershed Algorithm-Based Image Augmentation for Assessment of Level Damage Sector In Post-After Natural Disasters.

Menurut *Li et al.* augmentasi data merupakan suatu proses untuk menambah data pelatihan melalui metode tertentu agar secara efektif dapat meningkatkan kualitas dari data pelatihan tanpa merusak informasi dan fitur (*Li et al., 2023*). Sedangkan algoritma watershed menurut *Thulasidass et al.* merupakan salah satu teknik dari suatu segmentasi gambar (*Thulasidass et al., 2021*). Segmentasi gambar sendiri adalah prosedur pemisahan gambar menjadi beberapa bagian tertentu (*Thulasidass et al., 2021*), sedangkan menurut *Kasturi et al.* menjelaskan bahwa hasil dari suatu segmentasi gambar merupakan gabungan dari beberapa segmen menjadi satu gambar (*Kasturi et al., 2017*).



Gambar 4.4. Arsitektur Sistem

Menerapkan hasil proses augmentasi data untuk teknik segmentasi untuk menilai tingkat kerusakan sector pasca bencana merupakan salah satu cara untuk mengetahui informasi yang ada pada suatu gambar. Pada gambar 4.4 memperlihatkan proses untuk mengetahui informasi pada suatu gambar menggunakan teknik segmentasi berdasarkan hasil augmentasi data. Pada penelitian kami teknik segmentasi menggunakan algoritma watershed dengan input data dari hasil proses augmentasi data untuk menilai tingkat kerusakan

sector pasca bencana alam. Langkah-langkah hasil proses augmentasi data untuk teknik segmentasi sebagai berikut:

Langkah 1: Input data.

Pada proses input data menggunakan data gambar, menurut *Albane et al.* terdapat beberapa jenis input data yaitu gambar, pola, grafik, atau video yang membutuhkan suatu pengertian dalam bentuk grafik yang cukup kuat agar mudah dalam pemrosesan dan analisis dalam tahapan selanjutnya (*Albane et al.*, 2018). Pada penelitian kami menggunakan input data berupa gambar kerusakan sector pasca bencana alam.

Langkah 2: Proses PCA

Pada proses selanjutnya yaitu melakukan reduksi parameter. Pada penelitiannya *Almais et al.* menjelaskan bahwa untuk menentukan tingkat kerusakan sector pasca bencana alam dapat direduksi menggunakan teknik PCA menjadi 2 parameter saja yaitu keadaan bangunan dan keadaan struktur bangunan (*Almais et al.*, 2023).

Langkah 3: Proses Resize Crop Image

Menurut *Alex et al.* pada machine learning banyak yang menerapkan teknik augmentasi data karena dapat meningkatkan data pelatihan (*Alex et al.*, 2023). Terdapat banyak jenis augmentasi data diantaranya adalah flipping, color space, cropping, rotation, translation, noise injection (*Garcea et al.*, 2023; *Gordienko et al.*, 2021). Pada penelitian kami menggunakan teknik cropping karena data gambar hasil langkah 1 akan melalui proses cropping berdasarkan parameter hasil dari langkah 2.

Langkah 4: Proses merubah gambar menjadi bentuk RGB

Menurut *Ting et al.* mengubah gambar menjadi RGB melalui beberapa tahapan salah satunya adalah memvektorkan fitur pada suatu gambar menjadi saluran R, G, dan B dengan tujuan untuk meningkatkan akurasi klasifikasi (*Ting et al.*, 2022), selain itu menurut *Zang et al.* mengubah gambar menjadi berwarna merupakan proses mengisi informasi warna yang hilang dari gambar monokrom (*Zang et al.*, 2023). Sehingga perlu adanya gambar yang berwarna sebelum gambar tersebut masuk proses selanjutnya.

Langkah 5: Proses merubah gambar menjadi Grey Scale

Menurut *Chen et al.* menjelaskan bahwa saat ini pewarnaan gambar abu-abu tetap menjadi tugas utama pada berbagai bidang seperti film animasi, pemrosesan gambar medis, dan berbagai computer vision (*Chen et al.*, 2021). Gambar grey scale merupakan salah satu input data untuk mengetahui informasi dari suatu gambar karena ukurannya tidak berat dan informasi yang ada cukup buat membantu memutuskan suatu masalah.

Langkah 6: Proses menghapus noise

Noise atau derau merupakan salah satu topik penelitian yang semakin signifikan. Menurut *Jiao et al.* menjelaskan bahwa teori mengahpur noise dapat membuat kualitas gambar menjadi meningkat dengan menganalisis karakteristiknya dan memfilter noise tersebut, sehingga muncul teori resonansi stokastik yang membuktikan bahwa noise dapat untuk meningkatkan sinyal, yang membawa inspirasi baru untuk pemrosesan gambar (*Jiao et al.*, 2023). Menghapus noise memiliki peran penting karena akan menghasilkan gambar yang kualitasnya meningkat sehingga gambar tersebut akan lebih bagus pada proses selanjutnya.

Langkah 7: Proses membagi background dan foreground

Pada segmentasi gambar membutuhkan keseimbangan antara background dan foreground untuk meningkatkan akurasi dari segmentasi gambar (*Yang et al.*, 2023). Sehingga proses membagi gambar menjadi background dan foreground sangat penting karena dapat mempengaruhi tingkat akurasi pada hasil segmentasi gambar.

Langkah 8: Analisis hasil segmentasi gambar

Hasil watershed segmentasi menurut *Kucharski et al.* adalah suatu gambar hasil dari transformasi algoritma watershed yang sudah membentuk bendungan di tepi sel yang mengelilingi cekungan tangkapan yang sesuai dengan badan sel (*Kucharski and Fabijańska*, 2021). Pada penelitian kami bendungan merupakan pengertian dari area sector yang rusak sedangkan sel adalah gambar sector kerusakan pasca bencana alam, jadi pada gambar yang sudah melewati proses augmentasi data terdapat beberapa bendungan tergantung jumlah sector yang rusak.

Langkah 9: Menilai tingkat kerusakan sector pasca bencana alam

Menilai tingkat kerusakan sector pasca bencana alam merupakan hasil akhir yang pada penelitian kami ini, dengan menggunakan standart tingkat kerusakan

sector pasca bencana alam yaitu rusak ringan, rusak sedang, dan rusak berat (Bachriwindi et al., 2019).

4.2. Outcome Penelitian

Terdapat 5 capaian outcome penelitian yaitu yang sudah tercapai, belum tercapai dan sedang/proses tercapai:

Tabel 4.1. Outcome Penelitian

No.	Judul	Bentuk	Nama Publisher	Status	Keterangan
1.	Principal Component Analysis-Based Data Clustering for Labeling of Level Damage Sector in Post-Natural Disasters	Journal	IEEE ACCESS	Publish	International Q1 DOI: 10.1109/ACCESS.2023.3275852
2.	SDDS: Damage Level Determination System for Post-Natural Disaster Sector Based on Building Characteristics	Proceeding	IEEE Explore	Accepted	International Conference on Mathematics, Statistics and Their Applications (ICMSA 2023)
3.	SASSD: A Smart Assessment System for Sectoral Damage After Natural Disasters Using Artificial Neural Networks	Proceeding	IEEE Explore	Accepted	2023 The IEEE International Conference on Computer System, Information Technology, and Electrical Engineering (COSITE)
4.	Integrasi Artificial Intelligence Dengan Geofisika Kebencanaan	Book (Ber-ISBN)	UIN Press	Proses Submit	Proses Submit
5.	Teknik Labeling Data Menggunakan Principal Component Analysis (PCA)	HAKI/Paten	Mandiri	Process Submit	Proses submit dokumen Paten
6.	Watershed Algorithm-Based Image Augmentation for Assessment of Level Damage Sector in Post-After Natural Disasters	Journal	Elsevier-Alexandria	Process Submit	International Q1

No.	Judul	Bentuk	Nama Publisher	Status	Keterangan
7.	Support Vector Machine-Based Data Clustering for Labeling of Level Damage Sector in Post-Natural Disasters	Journal	Nature	Process Submit	International Q1

BAB V

KESIMPULAN DAN SARAN

5.1. Kesimpulan

Mengkolaborasikan Keilmuan yang berbeda dengan menghasilkan suatu karya ilmiah yaitu proceeding merupakan salah satu penemuan para riset ini. Dua paper proceeding tersebut berjudul **“SDDS: Damage Level Determination System for Post-Natural Disaster Sector Based on Building Characteristics”** dan **“SASSD: A Smart Assessment System for Sectoral Damage After Natural Disasters Using Artificial Neural Networks”**. Untuk judul **“SDDS”** focus pada keilmuan Decision Support System (DSS) sedangkan paper yang berjudul **“SASSD”** berfokus pada keilmuan Machine Learning (ML). Untuk paper yang berjudul **“SASSD”** menggunakan data hasil dari paper **“SDDS”**. Jika dua paper tersebut di kolaborasikan menjadi salah satu bentuk implementasi dari kolaborasi keilmuan DSS dengan ML.

Untuk paper yang berjudul **“Principal Component Analysis-Based Data Clustering for Labeling of Level Damage Sector in Post-Natural Disasters”** dan **“Watershed Algorithm-Based Image Augmentation for Assessment of Level Damage Sector in Post-After Natural Disasters”** merupakan salah satu hasil penemuan (**novelty**) pada riset kami. Karena banyak riset tentang Machi Learning (ML) focus pada pokok permasalahannya, tetapi dari hasil riset kita ini mencoba focus pada pre-processing data. hasilnya salah satu hasil riset kami telah publish di jurnal international terindex IEEE ACCESS Scopus Q1 dengan judul jurnal **“Principal Component Analysis-Based Data Clustering for Labeling of Level Damage Sector in Post-Natural Disasters”**, sedangkan untuk paper yang berjudul **“Watershed Algorithm-Based Image Augmentation for Assessment of Level Damage Sector in Post-After Natural Disasters”** juga membahas pre-processing data.

5.2. Saran

Penelitian yang sudah dilakukan menghasilkan banyak outcome sesuai dengan data outcome pada tabel 4.1. dari semua outcome tersebut jika dapat di simpulkan bahwa penelitian ini memiliki grand riset yang tinggi dan bagus untuk masa depan. Selain itu riset di pre-processing masih sedikit peminat untuk melakukan riset. Oleh sebab itu perlu dilakukan riset pada zona pre-processing data lebih lama dan intens agar menemukan novelty-novelty yang lainnya.

REFERENCES

- Abdellatif, M., Peel, H., Cohn, A.G., Fuentes, R., 2021. Combining block-based and pixel-based approaches to improve crack detection and localisation. *Autom Constr* 122, 103492. <https://doi.org/10.1016/j.autcon.2020.103492>
- Ahmad, Z., Jindal, R., N.S., M., Ekbal, A., Bhattacharyya, P., 2022. Multi-modality helps in crisis management: An attention-based deep learning approach of leveraging text for image classification. *Expert Syst Appl* 195, 116626. <https://doi.org/10.1016/j.eswa.2022.116626>
- Ahsan, M., Mahmud, M., Saha, P., Gupta, K., Siddique, Z., 2021. Effect of Data Scaling Methods on Machine Learning Algorithms and Model Performance. *Technologies (Basel)* 9, 52. <https://doi.org/10.3390/technologies9030052>
- Albane, S., Slimani, H., Kheddouci, H., 2018. Graph grammars according to the type of input and manipulated data: A survey. *Comput Sci Rev* 28, 178–203. <https://doi.org/10.1016/j.cosrev.2018.04.001>
- Alex, A., Wang, L., Gastaldo, P., Cavallaro, A., 2023. Data augmentation for speech separation. *Speech Commun.* <https://doi.org/10.1016/j.specom.2023.05.009>
- Almais, A.T., Fatchurrohman, F., Holle, K.F.H., 2020. Implementasi fuzzy weighted product penyusunan aksi rehabilitasi rekonstruksi pasca bencana berbasis decision support system dynamic. *JURNAL ELTEK* 18, 1. <https://doi.org/10.33795/eltek.v18i1.171>
- Almais, A.T.W., Fatchurrohman, ., Holle, K.F.H., Kinasih, K.S., Wiranti, D.A., Yasin, S.Y., 2019. Implementation Fuzzy Weighted Product Preparation Post Disaster Reconstruction and Rehabilitation Action based Dynamics Decision Support System, in: *Proceedings of the International Conferences on Information System and Technology. SCITEPRESS - Science and Technology Publications*, pp. 272–277. <https://doi.org/10.5220/0009909002720277>
- Almais, A.T.W., Susilo, A., Naba, A., Sarosa, M., Crysdiyan, C., Wicaksono, H., Tazi, I., Hariyadi, M.A., Muslim, M.A., Basid, P.M.N.S.A., Arif, Y.M., Purwanto, M.S., Parwatiningsy, D., Supriyono, 2023. Principal Component Analysis-Based Data Clustering for Labeling of Level Damage Sector in Post-Natural Disasters. *IEEE Access* 1. <https://doi.org/10.1109/ACCESS.2023.3275852>
- Aly, R.H.M., Rahouma, K.H., Hamed, H.F.A., 2019. Brain Tumors Diagnosis and Prediction Based on Applying the Learning Metaheuristic Optimization Techniques of Particle Swarm, Ant Colony and Bee Colony. *Procedia Comput Sci* 163, 165–179. <https://doi.org/10.1016/j.procs.2019.12.098>
- Aptikom, 2020. Artificial Intelligence, in: *Buletin Aptikom. Jakarta Selatan.*
- Bachriwindi, A., Putra, E.K., Munawaroh, U.M., Almais, A.T.W., 2019. Implementation of Web-Based Weighted Product Use Decision Support System to Determine the Post-

- Disaster Damage and Loss. *J Phys Conf Ser* 1413, 12019. <https://doi.org/10.1088/1742-6596/1413/1/012019>
- Bagi, Y.S., Suyono, S., Tomatala, M.F., 2020. Decision Support System for High Achieving Students Selection Using AHP and TOPSIS, in: 2020 2nd International Conference on Cybernetics and Intelligent System (ICORIS). IEEE, pp. 1–5. <https://doi.org/10.1109/ICORIS50180.2020.9320823>
- Basile, F., Ferrara, L., 2023. Validation of Industrial Automation Systems Using a Timed Model of System Requirements. *IEEE Transactions on Control Systems Technology* 31, 130–143. <https://doi.org/10.1109/TCST.2022.3173890>
- Batioua, I., Benouini, R., Zenkouar, K., Zahi, A., 2018. Image classification using separable invariants moments based on Racah polynomials. *Procedia Comput Sci* 127, 320–327. <https://doi.org/10.1016/j.procs.2018.01.128>
- Bhisop Christopher M., 1995. *Neural Networks for Pattern Recognition*. Clarendon, Oxford.
- Byabazaire, J., O’Hare, G.M.P., Delaney, D.T., 2022. End-to-End Data Quality Assessment Using Trust for Data Shared IoT Deployments. *IEEE Sens J* 22, 19995–20009. <https://doi.org/10.1109/JSEN.2022.3203853>
- Çelikbilek, Y., Tüysüz, F., 2020. An in-depth review of theory of the TOPSIS method: An experimental analysis. *Journal of Management Analytics* 7, 281–300. <https://doi.org/10.1080/23270012.2020.1748528>
- Chai, E., Ta, L., Ma, Z., Zhi, M., 2021. ERF-YOLO: A YOLO algorithm compatible with fewer parameters and higher accuracy. *Image Vis Comput* 116, 104317. <https://doi.org/10.1016/j.imavis.2021.104317>
- Chakraborty, S., 2022. TOPSIS and Modified TOPSIS: A comparative analysis. *Decision Analytics Journal* 2, 100021. <https://doi.org/10.1016/j.dajour.2021.100021>
- Chalavadi, V., Jeripothula, P., Datla, R., Ch, S.B., C, K.M., 2022. mSODANet: A network for multi-scale object detection in aerial images using hierarchical dilated convolutions. *Pattern Recognit* 126, 108548. <https://doi.org/10.1016/j.patcog.2022.108548>
- Charles, V.B., Surendran, D., SureshKumar, A., 2022. Heart disease data based privacy preservation using enhanced ElGamal and ResNet classifier. *Biomed Signal Process Control* 71, 103185. <https://doi.org/10.1016/j.bspc.2021.103185>
- Chen, C., Wei, J., Peng, C., Qin, H., 2021. Depth-Quality-Aware Salient Object Detection. *IEEE Transactions on Image Processing* 30, 2350–2363. <https://doi.org/10.1109/TIP.2021.3052069>
- Chu, H., Ma, H., Li, X., 2021. Pedestrian instance segmentation with prior structure of semantic parts. *Pattern Recognit Lett* 149, 9–16. <https://doi.org/10.1016/j.patrec.2021.05.012>
- Das, A.K., Kalam, S., Kumar, C., Sinha, D., 2021. TLCoV- An automated Covid-19 screening model using Transfer Learning from chest X-ray images. *Chaos Solitons Fractals* 144, 110713. <https://doi.org/10.1016/j.chaos.2021.110713>

- Fan, Z., Xia, W., Liu, X., Li, H., 2021. Detection and segmentation of underwater objects from forward-looking sonar based on a modified Mask RCNN. *Signal Image Video Process* 15, 1135–1143. <https://doi.org/10.1007/s11760-020-01841-x>
- Fatichah, C., 2021. Membangun Model, in: *Data Scientist: Artificial Intelligence Untuk Dosen Dan Instruktur*.
- Garcea, F., Serra, A., Lamberti, F., Morra, L., 2023. Data augmentation for medical imaging: A systematic literature review. *Comput Biol Med* 152, 106391. <https://doi.org/10.1016/j.compbiomed.2022.106391>
- Gonçalves, C.B., Souza, J.R., Fernandes, H., 2022. CNN architecture optimization using bio-inspired algorithms for breast cancer detection in infrared images. *Comput Biol Med* 142, 105205. <https://doi.org/10.1016/j.compbiomed.2021.105205>
- Gonzalez-Arias, C., Viafara, C.C., Coronado, J.J., Martinez, F., 2019. Automatic classification of severe and mild wear in worn surface images using histograms of oriented gradients as descriptor. *Wear* 426–427, 1702–1711. <https://doi.org/10.1016/j.wear.2018.11.028>
- Gordienko, Y., Kostiukevych, K., Gordienko, N., Rokovyi, O., Alienin, O., Stirenko, S., 2021. Deep Learning with Noise Data Augmentation and Detrended Fluctuation Analysis for Physical Action Classification by Brain-Computer Interface, in: *2021 8th International Conference on Soft Computing & Machine Intelligence (ISCMI)*. IEEE, pp. 176–180. <https://doi.org/10.1109/ISCMI53840.2021.9654829>
- Gu, T., 2020. Detection of Small Floating Targets on the Sea Surface Based on Multi-Features and Principal Component Analysis. *IEEE Geoscience and Remote Sensing Letters* 17, 809–813. <https://doi.org/10.1109/LGRS.2019.2935262>
- Gupta, A., Watson, S., Yin, H., 2021. Deep learning-based aerial image segmentation with open data for disaster impact assessment. *Neurocomputing* 439, 22–33. <https://doi.org/10.1016/j.neucom.2020.02.139>
- Hadiguna, R.A., Kamil, I., Delati, A., Reed, R., 2014. Implementing a web-based decision support system for disaster logistics: A case study of an evacuation location assessment for Indonesia. *International Journal of Disaster Risk Reduction* 9, 38–47. <https://doi.org/10.1016/j.ijdr.2014.02.004>
- Han, D., Liu, Q., Fan, W., 2018. A new image classification method using CNN transfer learning and web data augmentation. *Expert Syst Appl* 95, 43–56. <https://doi.org/10.1016/j.eswa.2017.11.028>
- Hendria, W.F., Phan, Q.T., Adzaka, F., Jeong, C., 2021. Combining transformer and CNN for object detection in UAV imagery. *ICT Express*. <https://doi.org/10.1016/j.icte.2021.12.006>
- Hu, Y., Chen, Z., Lin, W., 2018. RGB-D Semantic Segmentation: A Review, in: *2018 IEEE International Conference on Multimedia & Expo Workshops (ICMEW)*. IEEE, pp. 1–6. <https://doi.org/10.1109/ICMEW.2018.8551554>

- Huang, D., Wang, C.-D., Peng, H., Lai, J., Kwoh, C.-K., 2021. Enhanced Ensemble Clustering via Fast Propagation of Cluster-Wise Similarities. *IEEE Trans Syst Man Cybern Syst* 51, 508–520. <https://doi.org/10.1109/TSMC.2018.2876202>
- Huang, F., Xia, J., Yin, C., Zhai, X., Xu, N., Yang, G., Bai, W., Sun, Y., Du, Q., Liao, M., Hu, X., Zhang, P., Duan, L., Liu, Y., 2022. Assessment of FY-3E GNOS-II GNSS-R Global Wind Product. *IEEE J Sel Top Appl Earth Obs Remote Sens* 15, 7899–7912. <https://doi.org/10.1109/JSTARS.2022.3205331>
- Iswan, Garniwa, I., 2017. Principal component analysis and cluster analysis for development of electrical system, in: 2017 15th International Conference on Quality in Research (QiR) : International Symposium on Electrical and Computer Engineering. IEEE, pp. 439–443. <https://doi.org/10.1109/QIR.2017.8168526>
- Jiao, S., Shi, J., Wang, Y., Wang, R., 2023. A novel image noise reduction method for composite multistable stochastic resonance systems. *Heliyon* 9, e14431. <https://doi.org/10.1016/j.heliyon.2023.e14431>
- Kai, Z., Daojing, L., Anjing, C., Dong, H., He, T., Haifeng, Y., Jianbo, D., Lei, L., Yu, Z., Running, Z., 2021. Sparse flight spotlight mode 3-D imaging of spaceborne SAR based on sparse spectrum and principal component analysis. *Journal of Systems Engineering and Electronics* 32, 1143–1151. <https://doi.org/10.23919/JSEE.2021.000098>
- Kasturi, M.M., Sutha, P., Jayanthi, V.E., 2017. Efficient edge detection method for diagnosis of 2D and 3D lung and liver images, in: 2017 International Conference on Inventive Systems and Control (ICISC). IEEE, pp. 1–5. <https://doi.org/10.1109/ICISC.2017.8068661>
- Kong, M.-C., Roh, M.-I., Kim, K.-S., Lee, J., Kim, J., Lee, G., 2022. Object detection method for ship safety plans using deep learning. *Ocean Engineering* 246, 110587. <https://doi.org/10.1016/j.oceaneng.2022.110587>
- Kucharski, A., Fabijańska, A., 2021. CNN-watershed: A watershed transform with predicted markers for corneal endothelium image segmentation. *Biomed Signal Process Control* 68, 102805. <https://doi.org/10.1016/j.bspc.2021.102805>
- Lambers, M., Nies, H., Kolb, A., 2008. Interactive Dynamic Range Reduction for SAR Images. *IEEE Geoscience and Remote Sensing Letters* 5, 507–511. <https://doi.org/10.1109/LGRS.2008.922732>
- Li, D., Liu, F., Shen, T., Chen, L., Zhao, D., 2023. Data augmentation method for underwater acoustic target recognition based on underwater acoustic channel modeling and transfer learning. *Applied Acoustics* 208, 109344. <https://doi.org/10.1016/j.apacoust.2023.109344>
- Li, L., Han, L., Ding, M., Cao, H., Hu, H., 2021. A deep learning semantic template matching framework for remote sensing image registration. *ISPRS Journal of Photogrammetry and Remote Sensing* 181, 205–217. <https://doi.org/10.1016/j.isprsjprs.2021.09.012>
- Li, X., Zhai, M., Sun, J., 2021. DDCNNC: Dilated and depthwise separable convolutional neural Network for diagnosis COVID-19 via chest X-ray images. *International Journal*

- of Cognitive Computing in Engineering 2, 71–82.
<https://doi.org/10.1016/j.ijcce.2021.04.001>
- Liu, Y., Wu, L., 2016. Geological Disaster Recognition on Optical Remote Sensing Images Using Deep Learning. *Procedia Comput Sci* 91, 566–575.
<https://doi.org/10.1016/j.procs.2016.07.144>
- Ma, J., Zheng, L., Dong, M., He, X., Guo, M., Yaguchi, Y., Oka, R., 2013. A segmentation-free method for image classification based on pixel-wise matching. *J Comput Syst Sci* 79, 256–268. <https://doi.org/10.1016/j.jcss.2012.05.009>
- Mirhaji, H., Soleymani, M., Asakereh, A., Abdanan Mehdizadeh, S., 2021. Fruit detection and load estimation of an orange orchard using the YOLO models through simple approaches in different imaging and illumination conditions. *Comput Electron Agric* 191, 106533. <https://doi.org/10.1016/j.compag.2021.106533>
- Noh, H., Hong, S., Han, B., 2015. Learning Deconvolution Network for Semantic Segmentation, in: 2015 IEEE International Conference on Computer Vision (ICCV). IEEE, pp. 1520–1528. <https://doi.org/10.1109/ICCV.2015.178>
- Pan, Y., Jing, Y., Wu, T., Kong, X., 2022. Knowledge-based data augmentation of small samples for oil condition prediction. *Reliab Eng Syst Saf* 217, 108114. <https://doi.org/10.1016/j.ress.2021.108114>
- Pangarso, G., Kusumanigrum, R., 2019. Segmentasi Citra Obyek Buah Menggunakan Ohta Colour Space dan Niblack Adaptive Local Thresholding, in: SENTIKA.
- Premachandra, C., Premachandra, H.W.H., Parape, C.D., Kawanaka, H., 2015. Road crack detection using color variance distribution and discriminant analysis for approaching smooth vehicle movement on non-smooth roads. *International Journal of Machine Learning and Cybernetics* 6, 545–553. <https://doi.org/10.1007/s13042-014-0240-6>
- Putra, D., 2010. *Pengolahan Citra Digital*. Andi, Yogyakarta.
- Qiao, Y., Truman, M., Sukkarieh, S., 2019. Cattle segmentation and contour extraction based on Mask R-CNN for precision livestock farming. *Comput Electron Agric* 165, 104958. <https://doi.org/10.1016/j.compag.2019.104958>
- Ren, L., Zhang, Y., Wang, Y., Sun, Z., 2010. Comparative Analysis of a Novel M-TOPSIS Method and TOPSIS. *Applied Mathematics Research eXpress*. <https://doi.org/10.1093/amrx/abm005>
- Safitri, A.H., Wibowo Almais, A.T., Syauqi, A., Melani, R.I., 2022. Testing Optimization and Non-Optimization Query Topsis Methods to Determine Damage Level in Natural Disaster Sector. *Jurnal ELTIKOM* 6, 89–99. <https://doi.org/10.31961/eltikom.v6i1.532>
- Sarvani, C.H., Ghorai, M., Dubey, S.R., Basha, S.H.S., 2022. HRel: Filter pruning based on High Relevance between activation maps and class labels. *Neural Networks* 147, 186–197. <https://doi.org/10.1016/j.neunet.2021.12.017>

- Saxena, N., Day-Stirrat, R.J., Hows, A., Hofmann, R., 2021. Application of deep learning for semantic segmentation of sandstone thin sections. *Comput Geosci* 152, 104778. <https://doi.org/10.1016/j.cageo.2021.104778>
- Shao, F., Chen, L., Shao, J., Ji, W., Xiao, S., Ye, L., Zhuang, Y., Xiao, J., 2022. Deep Learning for Weakly-Supervised Object Detection and Localization: A Survey. *Neurocomputing*. <https://doi.org/10.1016/j.neucom.2022.01.095>
- Smith, L.I., 2002. A tutorial on Principal Components Analysis.
- Su, S., Chaniotakis, E., Narayanan, S., Jiang, H., Antoniou, C., 2022. Clustered tabu search optimization for reservation-based shared autonomous vehicles. *Transportation Letters* 14, 124–128. <https://doi.org/10.1080/19427867.2020.1824309>
- Sun, J., Li, X., Tang, C., Wang, S.-H., Zhang, Y.-D., 2021. MFBCNNC: Momentum factor biogeography convolutional neural network for COVID-19 detection via chest X-ray images. *Knowl Based Syst* 232, 107494. <https://doi.org/10.1016/j.knosys.2021.107494>
- Susilo, V., Isnanto, R.R., Riyadi, M.A., 2020. Herbal Leaf Pattern Analisis Using Principal Component Analisis (PCA) and Canberra Distance, in: 2020 7th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE). IEEE, pp. 100–104. <https://doi.org/10.1109/ICITACEE50144.2020.9239235>
- Thabet, A., Gasmi, N., Frej, G.B.H., Boutayeb, M., 2021. Sliding Mode Control for Lipschitz Nonlinear Systems in Reciprocal State Space: Synthesis and Experimental Validation. *IEEE Transactions on Circuits and Systems II: Express Briefs* 68, 948–952. <https://doi.org/10.1109/TCSII.2020.3018016>
- Thi Ngo, P.T., Panahi, M., Khosravi, K., Ghorbanzadeh, O., Kariminejad, N., Cerda, A., Lee, S., 2021. Evaluation of deep learning algorithms for national scale landslide susceptibility mapping of Iran. *Geoscience Frontiers* 12, 505–519. <https://doi.org/10.1016/j.gsf.2020.06.013>
- Thulasidass, S., Soundari, D.V., Chinnapparaj, S., Naveen, R., 2021. Liver tumor diagnosis by using hybrid watershed segmentation method. *Mater Today Proc* 37, 2848–2857. <https://doi.org/10.1016/j.matpr.2020.08.660>
- Tian, Y., Yang, G., Wang, Z., Li, E., Liang, Z., 2020. Instance segmentation of apple flowers using the improved mask R-CNN model. *Biosyst Eng* 193, 264–278. <https://doi.org/10.1016/j.biosystemseng.2020.03.008>
- Ting, Y.-H., Chen, Y.-M., Chen, L.-K., 2022. Enhancing Classification Performance for Android Small Sample Malicious Families Using Hybrid RGB Image Augmentation Method, in: 2022 9th International Conference on Soft Computing & Machine Intelligence (ISCMI). IEEE, pp. 21–25. <https://doi.org/10.1109/ISCMI56532.2022.10068453>
- Tripathi, M., 2021. Analysis of Convolutional Neural Network based Image Classification Techniques. *Journal of Innovative Image Processing* 3, 100–117. <https://doi.org/10.36548/jiip.2021.2.003>

- Troccoli, E.B., Cerqueira, A.G., Lemos, J.B., Holz, M., 2022. K-means clustering using principal component analysis to automate label organization in multi-attribute seismic facies analysis. *J Appl Geophy* 198, 104555. <https://doi.org/10.1016/j.jappgeo.2022.104555>
- Uddin, M.P., Mamun, M.A., Hossain, M.A., 2017. Feature extraction for hyperspectral image classification, in: 2017 IEEE Region 10 Humanitarian Technology Conference (R10-HTC). IEEE, pp. 379–382. <https://doi.org/10.1109/R10-HTC.2017.8288979>
- Upschulte, E., Harmeling, S., Amunts, K., Dickscheid, T., 2022. Contour proposal networks for biomedical instance segmentation. *Med Image Anal* 77, 102371. <https://doi.org/10.1016/j.media.2022.102371>
- Valdez, D.B., Godmalin, R.A.G., 2021. A Deep Learning Approach of Recognizing Natural Disasters on Images using Convolutional Neural Network and Transfer Learning, in: Proceedings of the International Conference on Artificial Intelligence and Its Applications. ACM, New York, NY, USA, pp. 1–7. <https://doi.org/10.1145/3487923.3487927>
- Victor Ikehukwu, A., Murali, S., Deepu, R., Shivamurthy, R.C., 2021. ResNet-50 vs VGG-19 vs training from scratch: A comparative analysis of the segmentation and classification of Pneumonia from chest X-ray images. *Global Transitions Proceedings* 2, 375–381. <https://doi.org/10.1016/j.gltp.2021.08.027>
- Wang, Changshuo, Wang, Chen, Li, W., Wang, H., 2021. A brief survey on RGB-D semantic segmentation using deep learning. *Displays* 70, 102080. <https://doi.org/10.1016/j.displa.2021.102080>
- Wang, M., Yang, L., Zhao, Z., Guo, Y., 2022. Intelligent prediction of wear location and mechanism using image identification based on improved Faster R-CNN model. *Tribol Int* 169, 107466. <https://doi.org/10.1016/j.triboint.2022.107466>
- Wang, Y., Fang, Z., Hong, H., 2019. Comparison of convolutional neural networks for landslide susceptibility mapping in Yanshan County, China. *Science of The Total Environment* 666, 975–993. <https://doi.org/10.1016/j.scitotenv.2019.02.263>
- Wibowo Almais, A.T., Sarosa, M., Muslim, M.A., 2016. Implementation Of Multi Experts Multi Criteria Decision Making For Rehabilitation And Reconstruction Action After A Disaster. *MATICS* 8, 27. <https://doi.org/10.18860/mat.v8i1.3480>
- Wu, J.-S., Zheng, W.-S., Lai, J.-H., Suen, C.Y., 2018. Euler Clustering on Large-Scale Dataset. *IEEE Trans Big Data* 4, 502–515. <https://doi.org/10.1109/TBDATA.2017.2742530>
- Xiao, J., Liu, G., Wang, K., Si, Y., 2022. Cow identification in free-stall barns based on an improved Mask R-CNN and an SVM. *Comput Electron Agric* 194, 106738. <https://doi.org/10.1016/j.compag.2022.106738>
- Xu, H., Huang, Y., Hancock, E.R., Wang, S., Xuan, Q., Zhou, W., 2021. Pooling Attention-based Encoder–Decoder Network for semantic segmentation. *Computers & Electrical Engineering* 93, 107260. <https://doi.org/10.1016/j.compeleceng.2021.107260>

- Yang, J., Matsushita, B., Zhang, H., 2023. Improving building rooftop segmentation accuracy through the optimization of UNet basic elements and image foreground-background balance. *ISPRS Journal of Photogrammetry and Remote Sensing* 201, 123–137. <https://doi.org/10.1016/j.isprsjprs.2023.05.013>
- Yu, Y., Zhang, K., Yang, L., Zhang, D., 2019. Fruit detection for strawberry harvesting robot in non-structural environment based on Mask-RCNN. *Comput Electron Agric* 163, 104846. <https://doi.org/10.1016/j.compag.2019.06.001>
- Zang, S., Chen, M., Ai, Z., Chi, J., Yang, G., Chen, C., Yu, T., 2023. Texture-aware gray-scale image colorization using a bistream generative adversarial network with multi scale attention structure. *Eng Appl Artif Intell* 122, 106094. <https://doi.org/10.1016/j.engappai.2023.106094>
- Zhang, K., Wang, W., Lv, Z., Fan, Y., Song, Y., 2021. Computer vision detection of foreign objects in coal processing using attention CNN. *Eng Appl Artif Intell* 102, 104242. <https://doi.org/10.1016/j.engappai.2021.104242>
- Zhang, X., Zhao, C., Luo, H., Zhao, W., Zhong, S., Tang, L., Peng, J., Fan, J., 2022. Automatic learning for object detection. *Neurocomputing*. <https://doi.org/10.1016/j.neucom.2022.02.012>
- Zyoud, S.H., Fuchs-Hanusch, D., 2017. A bibliometric-based survey on AHP and TOPSIS techniques. *Expert Syst Appl* 78, 158–181. <https://doi.org/10.1016/j.eswa.2017.02.016>

LAMPIRAN