

**KLASIFIKASI CITRA HIPERSPEKTRAL PADA TUTUPAN LAHAN
(*LAND COVER*) MENGGUNAKAN METODE *REGULARIZED HYBRID
CONVOLUTIONAL NEURAL NETWORK* DENGAN OPTIMASI
*ADAPTIVE MOMENT ESTIMATION***

(SKRIPSI)

Oleh

EZRA TAUFIQURRAHMAN

NPM 1915031049



**FAKULTAS TEKNIK
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2023**

ABSTRAK

KLASIFIKASI CITRA HIPERSPEKTRAL PADA TUTUPAN LAHAN (*LAND COVER*) MENGGUNAKAN METODE *REGULARIZED HYBRID CONVOLUTIONAL NEURAL NETWORK* DENGAN OPTIMASI *ADAPTIVE MOMENT ESTIMATION*

Oleh

EZRA TAUFIQURRAHMAN

Pemanfaatan citra hiperspektral dapat memberikan detail dan akurasi yang lebih tinggi dalam memantau lingkungan serta mengelola sumber daya alam melalui analisis tutupan lahan (*land cover*). Hal ini dikarenakan citra hiperspektral memiliki informasi spektral pada berbagai panjang gelombang yang diambil sehingga dapat membedakan berbagai jenis material dan informasi pada permukaan bumi dengan detail dan akurat. Beragam penelitian serta metode telah dilakukan untuk mengembangkan model klasifikasi citra hiperspektral pada tutupan lahan, namun struktur model yang rumit serta performa yang belum optimal menjadi tantangan untuk mengatasi masalah klasifikasi citra hiperspektral. Penelitian ini berhasil menerapkan metode dengan struktur yang lebih sederhana dengan mengembangkan CNN menggunakan metode *Regularized Hybrid CNN* dengan optimasi *Adaptive Moment Estimation* yang diuji pada dataset citra hiperspektral tutupan lahan *Pavia Center*. Dalam penelitian ini, hasil akurasi tertinggi yang didapatkan pada dataset ini sebesar 99.25 untuk *Overall Accuracy* dan 97.50 untuk *Average Accuracy*. Penelitian ini juga menganalisis perbandingan performa dengan metode CNN konvensional lainnya.

Kata kunci: Klasifikasi, *Convolutional Neural Network*, Hiperspektral.

ABSTRACT**CLASSIFICATION OF HYPERSPECTRAL IMAGERY ON LAND
COVER USING *REGULARIZED HYBRID CONVOLUTIONAL NEURAL
NETWORK* METHOD WITH *ADAPTIVE MOMENT ESTIMATION*
OPTIMIZATION****By****EZRA TAUFIQURRAHMAN**

The utilization of hyperspectral imagery can provide higher detail and accuracy in monitoring the environment and managing natural resources through land cover analysis. This is because hyperspectral images capture spectral information across various wavelengths, enabling the discrimination of different materials and surface information on Earth with *Precision* and accuracy. Various studies and methods have been conducted to develop hyperspectral image classification models for land cover, but the complex model structures and suboptimal performance remain challenges in addressing hyperspectral image classification issues. This research successfully applied a method with a simpler structure by developing a Convolutional Neural Network (CNN) using the Regularized Hybrid CNN approach with Adaptive Moment Estimation optimization, tested on the *Pavia Center* hyperspectral land cover dataset. In this study, the highest accuracy achieved was 99.25 for *Overall Accuracy* and 97.50 for *Average Accuracy*. Additionally, this research analyzed the performance comparison with other conventional CNN methods.

Keywords: Classification, Convolutional Neural Network, Hyperspectral.

**KLASIFIKASI CITRA HIPERSPEKTRAL PADA TUTUPAN LAHAN
(LAND COVER) MENGGUNAKAN METODE *REGULARIZED HYBRID
CONVOLUTIONAL NEURAL NETWORK* DENGAN OPTIMASI
*ADAPTIVE MOMENT ESTIMATION***

Oleh

EZRA TAUFIQURRAHMAN

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA TEKNIK**

Pada

**Jurusan Teknik Elektro
Fakultas Teknik Universitas Lampung**



**FAKULTAS TEKNIK
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2023**

Judul Skripsi

**: KLASIFIKASI CITRA HIPERSPEKTRAL
PADA TUTUPAN LAHAN (LAND COVER)
MENGUNAKAN METODE REGULARIZED
HYBRID CONVOLUTIONAL NEURAL
NETWORK DENGAN OPTIMASI ADAPTIVE
MOMENT ESTIMATION**

Nama Mahasiswa

: Ezra Taufiqurrahman

Nomor Pokok Mahasiswa : 1915031049

Program Studi

: Teknik Elektro

Fakultas

: Teknik



MENYETUJUI

1. Komisi Pembimbing

Yetti Yuniati, S.T., M.T.
NIP 198001132009122002

2. Mengetahui

Ketua Jurusan Teknik Elektro

Ketua Program Studi Teknik Elektro

Herlinawati, S.T., M.T.
NIP 197103141999032001

Dr. Eng. Nining Purwasih, S.T., M.T
NIP 197404222000122001

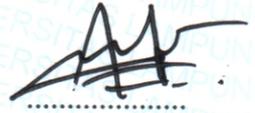
MENGESAHKAN

1. Tim Penguji

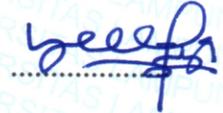
Ketua : Dr. Ing. Ardian Ulvan, S.T., M.sc



Sekretaris : Misfa Susanto, S.T., M.T., Ph.D



Penguji : Yetti Yuniati, S.T., M.T.



2. Dekan Fakultas Teknik




Dr. Eng. Ir. Helmy Fitriawan, S.T., M.Sc
NIP. 197509282001121002

Tanggal Lulus Ujian Skripsi : **12 Oktober 2023**

SURAT PERNYATAAN

Dengan ini saya menyatakan bahwa dalam skripsi ini tidak terdapat karya yang pernah dilakukan orang lain dan sepanjang sepengetahuan saya tidak terdapat atau diterbitkan oleh orang lain, kecuali secara tertulis diacu dalam naskah ini sebagaimana yang disebutkan dalam daftar Pustaka. Selain itu, saya menyatakan pula bahwa skripsi ini dibuat oleh saya sendiri.

Apabila pernyataan saya tidak benar, maka saya bersedia dikenai sanksi akademik sesuai dengan hukum yang berlaku.

Bandar Lampung, 12 Oktober 2023



Ezra Taufiqurrahman
NPM 1915031049

RIWAYAT HIDUP



Penulis dilahirkan di Jakarta pada tanggal 24 Juli 2000, sebagai anak pertama dari dua bersaudara, dari Bapak Erwin Zulkur Saeni (alm) dan Ibu Rosmawati Agustini.

Riwayat pendidikan penulis dimulai dari SD Al-Kaffah Batam Kota pada tahun 2007 hingga 2013, SMP Negeri 12 Batam Kota pada tahun 2013 hingga 2016, dan SMK SPN Dirgantara Batam pada tahun 2016 hingga tahun 2019.

Penulis menjadi mahasiswa Jurusan Teknik Elektro, Universitas Lampung, pada tahun 2019 melalui jalur SBMPTN. Selama menjadi mahasiswa penulis berkesempatan menjadi asisten praktikum pada mata kuliah Sistem Komunikasi di tahun 2022. Selain itu penulis juga tergabung dalam organisasi intra kampus UKM-U English Society Unila (ESO-Unila) yang pada tahun 2021 dan diamanahkan sebagai wakil presiden (vice president) pada tahun 2022. Penulis melaksanakan beberapa kegiatan Merdeka Belajar Kampus Merdeka selama dua kali di semester 6 dan semester 7. Penulis melaksanakan kegiatan studi independen di PT. *Orbit Future Academy* dan melaksanakan kegiatan riset mahasiswa di Badan Pengelola Perkebunan Kelapa Sawit (BPDPKS) pada Kegiatan Lomba Riset Sawit Tingkat Mahasiswa Tahun 2022. Selama menjadi mahasiswa di Universitas Lampung, penulis telah meraih dan mengikuti beberapa lomba dan kegiatan ekstra kampus diantaranya adalah penulis meraih Juara Tiga Lomba Debat Pendidikan yang diadakan oleh UNSRI tahun 2022 dan Menjadi Juri Undangan Pada Lomba Debat Nasional yang diadakan oleh Universitas Teknokrat dan lomba debat lainnya. Selain itu penulis juga berhasil meraih sebagai finalis dan tim 10 Terbaik pada lomba riset sawit tingkat mahasiswa oleh BPDPKS di tahun 2022.

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

“Dengan menyebut nama Allah yang Maha Pengasih lagi Maha Penyayang, Ku persembahkan dan Ku dedikasikan Skripsi ini untuk Saya sendiri, Kedua Orangtua saya, Almarhum Papa Erwin Zulkur Saeni dan Mama Rosmawati Agustini yang memberikan semua hal terbaik demi anaknya dalam mencapai kesuksesan”

MOTTO

“Karunia Allah yang paling lengkap adalah kehidupan yang didasarkan pada ilmu pengetahuan.”

(Ali bin Abi Thalib)

“Yesterday is history, tomorrow is a mystery, and today is a gift. That’s why they call it the present.”

(Master Oogway)

“When life gets you down, you know what you gotta do?
JUST KEEP SWIMMING.”

(Dory)

SAWACANA

Segala puji bagi Allah SWT, atas limpahan nikmat dan karunia-Nya yang diberikan kepada penulis sehingga dapat menyelesaikan Tugas Akhir ini. Shalawat dan salam senantiasa dicurahkan kepada Nabi Muhammad SAW, suri teladan yang mampu membuka sesuatu yang terkunci, penutup dari semua yang terdahulu, penolong kebenaran dengan jalan yang benar, dan petunjuk kepada jalan-Mu yang lurus.

Tugas Akhir dengan judul “Klasifikasi Citra Hiperspektral Pada Tutupan Lahan (*Land Cover*) Menggunakan Metode *Regularized Hybrid Convolutional Neural Network* Dengan Optimasi *Adaptive Moment Estimation*” ini merupakan salah satu syarat untuk memperoleh gelar Sarjana Teknik pada Jurusan Teknik Elektro, Fakultas Teknik, Universitas Lampung. Pada kesempatan ini, penulis mengucapkan terima kasih secara khusus dalam kelancaran penyelesaian skripsi ini kepada:

1. Ibu Yetti Yuniati, S.T., M.T., selaku dosen pembimbing utama yang selalu memberikan motivasi dan pandangan kehidupan, mengarahkan dan membimbing dengan tulus dan penuh kesabaran.
2. Bapak Dr. Ing. Ardian Ulvan, S.T., M.Sc., selaku dosen penguji pertama yang telah memberikan saran, kritik dan arahan dengan baik serta penuh motivasi.
3. Bapak Misfa Susanto, S.T., M.T., Ph.D., selaku dosen penguji kedua yang telah memberikan saran, kritik, dan arahan dengan baik dan teliti.

Tidak lupa penulis juga mengucapkan terimakasih kepada:

1. Ibu Prof. Dr. Ir. Lusmeilia Afriani, D.E.A., I.P.M., selaku Rektor Universitas Lampung.
2. Bapak Dr. Eng. Helmy Fitriawan, S.T., M.Sc., selaku Dekan Fakultas Teknik Universitas Lampung.
3. Ibu Herlinawati, S.T., M.T., selaku Ketua Jurusan Teknik Elektro Fakultas Teknik Universitas Lampung.

4. Ibu Yeti Yuniati, S.T., M.T., selaku dosen pembimbing utama yang selalu memberikan motivasi dan pandangan kehidupan, mengarahkan dan membimbing dengan tulus dan penuh kesabaran.
5. Bapak Dr. Ing. Ardian Ulvan, S.T., M.Sc., selaku dosen penguji pertama yang telah memberikan saran, kritik dan arahan dengan baik serta penuh motivasi.
6. Bapak Misfa Susanto, S.T., M.T., Ph.D., selaku dosen penguji kedua yang telah memberikan saran, kritik, dan arahan dengan baik dan teliti.
7. Bapak Syaiful Alam, S.T., M.T., selaku dosen Pembimbing Akademik (PA) yang telah memberikan nasihat, arahan, bimbingan dengan baik dan tulus bagi penulis selama perkuliahan
8. Ibu Dr. Ing. Melvi, S.T. M.T., yang telah membantu dan membimbing saya dalam perkuliahan di konsentrasi telekomunikasi dan teknik informasi.
9. Bapak dan Ibu Dosen Jurusan Teknik Elektro Fakultas Teknik Universitas Lampung yang telah memberikan pengajaran dan pandangan hidup selama perkuliahan.
10. Staff administrasi Jurusan Teknik Elektro dan Fakultas Teknik Universitas Lampung yang telah membantu penulis dalam hal administrasi.
11. Mama Rosmawati Agustini selaku orangtua yang terus memberikan motivasi, dukungan, nasihat, dan doa tanpa henti kepada penulis untuk menyelesaikan perkuliahan dengan baik.
12. Segenap Keluarga Besar Konsentrasi Telekomunikasi dan Teknik Informasi Universitas Lampung yang telah menyediakan wadah untuk selalu berkembang dan berprestasi.
13. Fifi Afyah Ramadita Hermawan yang telah membantu secara moril penuh kasih sayang dan selalu memberikan dukungan agar skripsi ini dapat terselesaikan dengan baik. Semoga segera menyusul dan dapat menyelesaikan perkuliahan dengan baik juga.
14. Segenap teman dan adik *debate branch* UKM-U ESo Unila, yang selalu semangat dan memberikan wadah untuk melepas penat selama perkuliahan ini. Semoga kalian tetap bisa meneruskan tongkat estafet kekeluargaan di *branch debate* ESo Unila.

15. Segenap keluarga besar UKM-U Eso Unila yang telah memberikan wadah untuk selalu berprestasi dan memberikan arti lain dari sebuah kekeluargaan.
16. Segenap Teman KKN Jatibening dan teman-teman lainnya yang tidak dapat penulis sebutkan satu persatu yang telah mengisi dunia perkuliahan dengan penuh suka cita.
17. Adele Adkins dan Lana Del Ray, yang telah menemani pengerjaan skripsi dengan lagu lagu indah yang sangat luar biasa.
18. Rayyanza Malik Ahmad keponakan *online* penulis, yang telah mengisi hari dengan kelucuan dan kegemasan mu sehari-hari sehingga penulis dapat melepas penat dari pengerjaan skripsi ini.
19. Semua pihak yang terlibat dalam proses perkuliahan dan penulisan skripsi ini penulis ucapkan terima kasih atas bantuan dan kerjasamanya.

Penulis menyadari bahwa dalam penulisan skripsi ini masih banyak kekurangan. Oleh karena itu, penulis mengharapkan kritik dan saran yang bersifat membangun demi kesempurnaan skripsi ini yang akan datang. Semoga skripsi ini dapat bermanfaat bagi penulis khususnya dan masyarakat pada umumnya.

Bandar Lampung, 12 Oktober 2023

Ezra Taufiqurrahman

DAFTAR ISI

	Halaman
DAFTAR ISI	xixiii
DAFTAR TABEL	xv
DAFTAR GAMBAR	xxvii
I. PENDAHULUAN	1
1.1. Latar Belakang dan Masalah	1
1.2. Tujuan	5
1.3. Rumusan Masalah.....	5
1.4. Batasan Penelitian.....	5
1.5. Manfaat Penelitian	6
1.6. Sistematika Penulisan	6
II. TINJAUAN PUSTAKA.....	8
2.1. Penelitian Terkait.....	8
2.2. Penginderaan Jauh	13
2.3. Spektrum Elektromagnetik.....	14
2.4. Penginderaan Jauh Hiperspektral	15
2.5. Tutupan Lahan.....	19
2.6. Praproses Data	20
2.7. Klasifikasi Citra Hiperspektral	21
2.7.1. <i>Convolutional Neural Network (CNN)</i>	22
2.7.2. <i>Arsitektur CNN</i>	23
2.7.3. <i>Two Dimensional CNN</i>	27
2.7.4. <i>Three Dimensional CNN</i>	28
2.7.5. <i>Regularized Hybrid CNN</i>	29
2.8. Metode Evaluasi	35
III. METODOLOGI PENELITIAN.....	39
3.1. Waktu dan Tempat Penelitian	39
3.2. Alat dan Bahan	39
3.3. Tahapan Penelitian.....	40
3.4. Pengumpulan Data.....	43

3.4.1.	Analisis Data	44
3.4.2.	Praproses Data	48
3.5.	Proses Klasifikasi	49
3.6.	Ekstrasi Fitur dan Klasifikasi	53
3.7.	Evaluasi	55
3.8.	Analisis Hasil Penelitian	57
3.9.	Komparasi Hasil Penelitian	57
3.10.	Kesimpulan Dan Saran	58
IV.	HASIL DAN PEMBAHASAN	59
4.1.	Hasil Pengujian Model 1	60
4.2.	Hasil Pengujian Model 2	67
4.3.	Hasil Pengujian Model 3	74
4.4.	Hasil Pengujian Model 4	81
4.5.	Hasil Pengujian Model 5	88
4.6.	Hasil Pengujian Model 6	95
4.7.	Hasil Pengujian Model 7	102
4.8.	Hasil Pengujian Model 8	109
4.9.	Hasil Pengujian Model 9	116
4.10.	Hasil Pengujian Model 10	123
4.11.	Hasil Pengujian Model 11	130
4.12.	Hasil Pengujian Model 12	137
4.13.	Hasil Pengujian Model 13	144
4.14.	Hasil Pengujian Model 14	151
4.15.	Evaluasi Perbandingan Kinerja Model	158
4.16.	Studi Perbandingan	163
V.	KESIMPULAN DAN SARAN	166
5.1.	Kesimpulan	166
5.2.	Saran	167
	DAFTAR PUSTAKA	168

DAFTAR TABEL

	Halaman
Tabel 2.1 Jenis Citra Hiperspektral.....	18
Tabel 3.1 Alat.....	39
Tabel 3.2 Bahan.....	40
Tabel 3.3 Spesifikasi dataset yang digunakan.....	44
Tabel 3.4 Kelas Dataset <i>Pavia</i> Centre (PC).....	45
Tabel 3.5 Arsitektur CNN Standar.....	48
Tabel 3.6 Arsitektur <i>Regularized Hybrid</i> CNN.....	49
Tabel 3.7 Percobaan Kombinasi Metode.....	52
Tabel 4.1 Percobaan Kombinasi Model.....	57
Tabel 4.2 Hasil Akurasi Model 1.....	58
Tabel 4.3 Hasil <i>Classification Report</i> Model 1.....	60
Tabel 4.4 Hasil Akurasi Model 2.....	65
Tabel 4.5 Hasil <i>Classification Report</i> Model 2.....	67
Tabel 4.6 Hasil Akurasi Model 3.....	72
Tabel 4.7 Hasil <i>Classification Report</i> Model 3.....	74
Tabel 4.8 Hasil Akurasi Model 4.....	79
Tabel 4.9 Hasil <i>Classification Report</i> Model 4.....	81
Tabel 4.10 Hasil Akurasi Model 5.....	86
Tabel 4.11 Hasil <i>Classification Report</i> Model 5.....	88
Tabel 4.12 Hasil Akurasi Model 6.....	93
Tabel 4.13 Hasil <i>Classification Report</i> Model 6.....	95
Tabel 4.14 Hasil Akurasi Model 7.....	100
Tabel 4.15 Hasil <i>Classification Report</i> Model 7.....	102
Tabel 4.16 Hasil Akurasi Model 8.....	107
Tabel 4.17 Hasil <i>Classification Report</i> Model 8.....	109
Tabel 4.18 Hasil Akurasi Model 9.....	114
Tabel 4.19 Hasil <i>Classification Report</i> Model 9.....	116
Tabel 4.20 Hasil Akurasi Model 10.....	121
Tabel 4.21 Hasil <i>Classification Report</i> Model 10.....	123

Tabel 4.22 Hasil Akurasi Model 11.....	128
Tabel 4.23 Hasil <i>Classification Report</i> Model 11	130
Tabel 4.24 Hasil Akurasi Model 12.....	135
Tabel 4.25 Hasil <i>Classification Report</i> Model 12.....	137
Tabel 4.26 Hasil Akurasi Model 13.....	142
Tabel 4.27 Hasil <i>Classification Report</i> Model 13	144
Tabel 4.28 Hasil Akurasi Model 14.....	149
Tabel 4.29 Hasil <i>Classification Report</i> Model 14	151
Tabel 4.30 Perbandingan Akurasi Model pada Dataset Pavia	156
Tabel 4.31 Perbandingan Hasil Akurasi Model Masing Masing Kelas Dataset Pavia.....	160
Tabel 4.32 Acuan Dataset Pavia Centre (PC)	161

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Roadmap Penelitian	12
Gambar 2.2 Prinsip Cara Kerja Penginderaan Jauh	13
Gambar 2.3 Ilustrasi Spektrum Elektromagnetik	15
Gambar 2.4 Konsep Hiperspektral	16
Gambar 2.5 Elektromagnetik Spektrum Citra RGB, Multispektral dan Hiperspektral.	17
Gambar 2.6 <i>Sliding Window</i>	20
Gambar 2.7 Arsitektur CNN Secara Umum.....	23
Gambar 2.8 CNN Model Dengan <i>Convolution Layers</i> , <i>Pooling Layers</i> dan <i>Full Connection Layer</i>	24
Gambar 2.9 Proses Operasi Konvolusi CNN	25
Gambar 2.10 Arsitektur 2D CNN.....	27
Gambar 2.11 Arsitektur 3D CNN	28
Gambar 2.12 Arsitektur <i>Hybrid CNN</i>	29
Gambar 2.13 <i>Standard Neural Network</i> dan <i>Dropout Neural Network</i>	34
Gambar 3.1 Diagram Alir Penelitian	43
Gambar 3.2 (a) False Color; (b) Groundtruth Dataset PC	45
Gambar 3.3 Visualisasi Data PC dalam beberapa Band Hiperspektral	46
Gambar 3.4 Praproses Data.....	48
Gambar 3.5 Tahapan Klasifikasi	47
Gambar 3.6 Ilustrasi Klasifikasi Citra Hiperspektral Tutupan Lahan	51
Gambar 3.7 <i>Source Code Library</i>	52
Gambar 3.8 <i>Confussion Matrix</i>	53
Gambar 4.1 <i>Confussion Matrix</i> Model 1 Dataset <i>Pavia</i>	59
Gambar 4.2 Uji Validitas Standar Deviasi Model 1	61
Gambar 4.3 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 1.....	62
Gambar 4.4 Hasil Peta Klasifikasi Model 1	63
Gambar 4.5 <i>Confussion Matrix</i> Model 2 Dataset <i>Pavia</i>	66
Gambar 4.6 Uji Validitas Standar Deviasi Model 2	68

Gambar 4.7 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 2.....	69
Gambar 4.8 Hasil Peta Klasifikasi Model 2.....	70
Gambar 4.9 <i>Confussion Matrix</i> Model 3 Dataset <i>Pavia</i>	73
Gambar 4.10 Uji Validitas Standar Deviasi Model 3	75
Gambar 4.11 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 3.....	76
Gambar 4.12 Hasil Peta Klasifikasi Model 4.....	77
Gambar 4.13 <i>Confussion Matrix</i> Model 4 Dataset <i>Pavia</i>	80
Gambar 4.14 Uji Validitas Standar Deviasi Model 4	82
Gambar 4.15 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 4.....	83
Gambar 4.16 Hasil Peta Klasifikasi Model 4.....	84
Gambar 4.17 <i>Confussion Matrix</i> Model 5 Dataset <i>Pavia</i>	87
Gambar 4.18 Uji Validitas Standar Deviasi Model 5	89
Gambar 4.19 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 5.....	90
Gambar 4.20 Hasil Peta Klasifikasi Model 5.....	91
Gambar 4.21 <i>Confussion Matrix</i> Model 6 Dataset <i>Pavia</i>	94
Gambar 4.22 Uji Validitas Standar Deviasi Model 6	96
Gambar 4.23 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 6.....	97
Gambar 4.24 Hasil Peta Klasifikasi Model 6.....	98
Gambar 4.25 <i>Confussion Matrix</i> Model 7 Dataset <i>Pavia</i>	101
Gambar 4.26 Uji Validitas Standar Deviasi Model 7	103
Gambar 4.27 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 7.....	104
Gambar 4.28 Hasil Peta Klasifikasi Model 7.....	105
Gambar 4.29 <i>Confussion Matrix</i> Model 8 Dataset <i>Pavia</i>	108
Gambar 4.30 Uji Validitas Standar Deviasi Model 8	110
Gambar 4.31 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 8.....	111
Gambar 4.32 Hasil Peta Klasifikasi Model 8.....	112
Gambar 4.33 <i>Confussion Matrix</i> Model 9 Dataset <i>Pavia</i>	115
Gambar 4.34 Uji Validitas Standar Deviasi Model 9	117
Gambar 4.35 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 9.....	118
Gambar 4.36 Hasil Peta Klasifikasi Model 9.....	119
Gambar 4.37 <i>Confussion Matrix</i> Model 10 Dataset <i>Pavia</i>	122
Gambar 4.38 Uji Validitas Standar Deviasi Model 10	124

Gambar 4.39 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 10.....	125
Gambar 4.40 Hasil Peta Klasifikasi Model 10.....	126
Gambar 4.41 <i>Confussion Matrix</i> Model 11 Dataset <i>Pavia</i>	129
Gambar 4.42 Uji Validitas Standar Deviasi Model 11	131
Gambar 4.43 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 11.....	132
Gambar 4.44 Hasil Peta Klasifikasi Model 11	133
Gambar 4.45 <i>Confussion Matrix</i> Model 12 Dataset <i>Pavia</i>	136
Gambar 4.46 Uji Validitas Standar Deviasi Model 12	138
Gambar 4.47 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 12.....	139
Gambar 4.48 Hasil Peta Klasifikasi Model 12.....	140
Gambar 4.49 <i>Confussion Matrix</i> Model 13 Dataset <i>Pavia</i>	144
Gambar 4.50 Uji Validitas Standar Deviasi Model 13	145
Gambar 4.51 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 13.....	146
Gambar 4.52 Hasil Peta Klasifikasi Model 13	147
Gambar 4.53 <i>Confussion Matrix</i> Model 14 Dataset <i>Pavia</i>	150
Gambar 4.54 Uji Validitas Standar Deviasi Model 14	152
Gambar 4.55 <i>Timestamp</i> Antara Setiap <i>Epoch</i> Model 14.....	153
Gambar 4.56 Hasil Peta Klasifikasi Model 14.....	154
Gambar 4.57 Perbandingan Akurasi Model.....	157
Gambar 4.58 Perbandingan Waktu Komputasional Setiap model	158
Gambar 4.59 Peta Hasil Klasifikasi (a) model 1; (b) model 2; (c) model 3; (d) model 4; (e) model 5; (f) model 6; (g) model 7; (h) model 8; (i) model 9; (j) model 10; (k) model 11; (l) model 12; (m) model 13; (n) model 14.....	159

I. PENDAHULUAN

1.1. Latar Belakang dan Masalah

Perkembangan wilayah dapat menyebabkan perubahan penampilan fisik, baik disebabkan oleh faktor manusia maupun alam. Hal ini sangatlah penting sehingga dibutuhkannya informasi yang akurat mengenai tutupan lahan untuk memahami fenomena yang terjadi di permukaan bumi dan menjadi dasar dalam perencanaan pengelolaan berbasis lahan [1]. Tutupan lahan sendiri merujuk pada jenis vegetasi atau penggunaan lahan pada suatu area tertentu. Hal ini dapat mencakup hutan, padang rumput, ladang pertanian, bangunan, jalan, dan lain sebagainya. Tutupan lahan ini dapat diukur dengan menggunakan teknologi penginderaan jauh (inderaja) atau dengan survei lapangan atau secara manual [2]. Pemantauan tutupan lahan secara manual tentu membutuhkan biaya yang sangat besar dan waktu yang tidak singkat. Teknologi penginderaan jauh (inderaja) dapat dimanfaatkan untuk melakukan analisis tutupan lahan sebagai dasar pemanfaatan dan perencanaan lahan tersebut, seperti dimanfaatkan untuk mengidentifikasi, mengevaluasi dan memantau tutupan lahan [3].

Penginderaan jauh (*remote sensing*) adalah teknologi yang menggunakan sensor atau instrumen di pesawat udara atau satelit untuk mengumpulkan informasi tentang lingkungan, seperti citra satelit atau spektrum elektromagnetik. Data penginderaan jauh dapat mencakup informasi tentang tutupan lahan, kualitas air, iklim, dan lainnya. Terdapat berbagai jenis data inderaja, seperti citra optik, citra fotografik, dan citra nonfotografik, yang diperoleh. Dari jenis citra tersebut, citra hiperspektral merupakan citra nonfotografik yang dapat memberikan informasi yang sangat akurat mengenai permukaan bumi [4]. Hal ini dikarenakan jenis data

yang diperoleh dari citra hiperspektral dapat mengambil spektrum elektromagnetik yang sangat rinci, biasanya mencakup ratusan atau bahkan ribuan rentang gelombang. Ini memungkinkan pengukuran yang sangat tepat dari karakteristik material dan komposisi permukaan bumi, seperti jenis tanaman dan kandungan air dalam tanaman. Oleh karena itu, hiperspektral sering dianggap sebagai jenis data penginderaan jauh yang paling akurat untuk analisis tutupan lahan [4].

Beberapa penelitian mengenai klasifikasi citra hiperspektral tutupan lahan telah banyak dilakukan. Penelitian oleh Chen, Q dkk pada tahun 2019 dengan judul *Hyperspectral Image Classification Based on Multi-Scale Local Binary Pattern and Multi-Kernel SVM* menggunakan komparasi model *Support Vector Machine (SVM)*, *random forest*, dan *Deep Neural network* untuk klasifikasi citra hiperspektral. Penelitian yang dilakukan oleh Yanan Guo dkk pada tahun 2019 dengan judul *Multiple Kernel SVM (MK-SVM) Based on Fractional Fourier Transform for Hyperspectral Image Classification* menggunakan *Multiple Kernel SVM (MK-SVM)* berbasis *fractional fourier transform* sebagai model klasifikasinya. Dua penelitian ini masih harus dikembangkan dalam data citra hiperspektral, hal ini dikarenakan pada penelitian tersebut hasil menunjukkan bahwa metode MK-SVM yang diusulkan menghasilkan akurasi yang belum mendekati sempurna yakni hanya mencapai akurasi sebesar 90,0%. Meskipun SVM mempunyai kinerja yang baik dalam klasifikasi dua kelas atau beberapa kelas, SVM cenderung kurang akurat dalam mengklasifikasikan citra hiperspektral dengan jumlah kelas yang banyak jika kernel yang digunakan tidak dioptimasi dengan baik. Seiring perkembangan zaman, kebutuhan akan keakuratan data semakin meningkat hal ini dikarenakan semakin optimal data yang digunakan maka hasil keakuratannya juga akan meningkat [5].

Beberapa penelitian klasifikasi citra hiperspektral pada tutupan lahan juga menggunakan citra dengan sensor pesawat. Penelitian oleh Jianfeng (2019) mengusulkan sebuah metode klasifikasi citra hiperspektral dengan menggunakan metode ekstraksi fitur *Local Binary Patterns (LBP)* dan metode pengambilan keputusan *Majority Voting* pada model *Support Vector Machines (SVM)*. Metode

ini diuji pada tiga dataset citra hiperspektral yang berbeda dan menghasilkan tingkat akurasi yang baik yakni mencapai 93,67% akurasi pada dataset *Indian Pines* [6]. Penelitian oleh Tianyi Wei (2019) menggunakan sebuah arsitektur *Convolutional Neural Networks* (CNN) yang memiliki beberapa jalur dan *field of view* yang berbeda untuk melakukan klasifikasi citra hiperspektral dengan hasil akurasi pada dataset *Indian Pines* yakni sebesar 97,7% dan dataset *Pavia* sebesar 98,7% [7]. Model yang telah digunakan pada penelitian-penelitian sebelumnya memang memiliki kemiripan dalam hasil akurasinya namun sampai saat ini masih belum terbukti bahwa model tersebut dapat menangani masalah ketimpangan dan keterbatasan sampel yang sering terjadi pada data penginderaan jauh hiperspektral contohnya ialah masalah *overfitting* pada klasifikasi hiperspektral yang terjadi ketika model yang dibuat terlalu kompleks dan terlalu spesifik dalam mempelajari data training sehingga tidak dapat memgeneralisasi dengan baik pada data baru, yang dapat mengakibatkan performa model pada data yang belum dilihat sebelumnya menjadi menurun, serta belum adanya perbandingan algoritma terbaik yang dapat diimplementasikan dan metode yang digunakan masih memerlukan beberapa struktur model yang rumit.

Berdasarkan uraian di atas, dapat disimpulkan bahwasannya CNN memiliki potensi untuk meningkatkan performa klasifikasi yang baik, namun sampai saat ini metode serta struktur yang digunakan masih rumit dan sulit untuk diimplementasikan secara langsung. Penelitian kali ini akan mengusulkan sebuah metode dengan mengembangkan CNN dalam mengklasifikasi citra hiperspektral yakni dengan metode *Regularized Hybrid CNN* dengan Optimasi *Adaptive Moment Estimation* (ADAM) yang diuji pada dataset citra hiperspektral *Pavia* berdasarkan instrumen AVIRIS. CNN merupakan algoritma *Neural Networks* yang sangat sederhana namun dapat berpotensi menghasilkan tingkat akurasi yang tinggi dalam mengklasifikasikan suatu data, selain itu karena memiliki kemampuan dalam mengekstrak fitur yang kompleks pada citra dengan jumlah kanal yang tinggi [8]. CNN memiliki metode klasifikasi yang sederhana karena kemampuannya dalam mempelajari fitur-fitur yang kompleks pada data citra hiperspektral yang memiliki dimensi yang besar. Selain itu, CNN juga mampu mengatasi masalah

ketidaklinieran pada data citra hiperspektral yang sulit diolah dengan metode klasifikasi konvensional [9]. CNN juga memiliki banyak variasi yang dapat dimodifikasi untuk mendapatkan hasil klasifikasi terbaik. Berdasarkan beberapa masalah dan uraian ini, peneliti mengusulkan metode *Regularized Hybrid CNN* dengan optimasi *adaptive moment estimation*. dalam mengklasifikasikan citra hiperspektral. Teknik Regularisasi yang diusulkan ini diharapkan dapat mengurangi kompleksitas dataset dan model yang digunakan pada model klasifikasi hiperspektral [10]. Dapat disimpulkan bahwa ada beberapa masalah dalam klasifikasi citra hiperspektral yang dapat ditemui salah satunya ialah *overfitting*. Overfitting terjadi ketika model pembelajaran mesin terlalu rumit atau memiliki terlalu banyak parameter dibandingkan dengan jumlah data pelatihan yang tersedia. Hasilnya, model ini dapat "menghafal" data pelatihan dengan sangat baik, tetapi gagal untuk menggeneralisasi dengan baik ke data baru atau data yang belum pernah dilihat sebelumnya [10].

Hybrid CNN digunakan sebagai pengembangan dari metode CNN konvensional dengan menggabungkan dua metode CNN *two dimensional* dan *three dimensional*. *Hybrid CNN* yang diusulkan pada penelitian ini menggunakan struktur model yang lebih sederhana mengingat bahwa salah satu masalah pada penelitian sebelumnya ialah kompleksitas model yang rumit. Penelitian ini akan menganalisis hasil performa dan efektifitas metode *Regularized Hybrid CNN* dalam mengatasi masalah masalah tersebut yakni mengusulkan teknik regularisasi yang sederhana menggunakan penggabungan *L2 Regularization* dan *drop out*. Selain itu, Penelitian ini juga akan membandingkan dengan menggunakan metode CNN konvensional menggunakan *hyperparameters* yang berbeda untuk menganalisis performa yang dihasilkan. Penelitian ini diharapkan berhasil untuk mengatasi masalah klasifikasi citra hiperspektral dengan performa yang optimal.

1.2. Tujuan

Tujuan penelitian ini adalah sebagai berikut :

1. Pengembangan kerangka kerja CNN untuk meningkatkan akurasi pada klasifikasi citra hiperspektral tutupan lahan pada dataset *pavia center*.
2. Membandingkan performa metode *Regularized Hybrid CNN* dengan CNN konvensional lainnya pada klasifikasi citra hiperspektral tutupan lahan dataset *pavia center*.

1.3. Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan di atas, aka masalah yang bisa peneliti rumuskan adalah :

1. Bagaimana kerangka kerja *Regularized Hybrid CNN* untuk meningkatkan efektivitas dan akurasi pada klasifikasi citra hiperspektral tutupan lahan?
2. Bagaimana pengaruh penggunaan metode *Regularized Hybrid CNN* dalam mengatasi masalah klasifikasi citra hiperspektral pada tutupan lahan?
3. Bagaimana perbandingan performa dan efektivitas dari metode *Regularized Hybrid CNN* dengan CNN konvensional dalam klasifikasi citra hiperspektral pada tutupan lahan?

1.4. Batasan Penelitian

Batasan masalah dari peneliltian ini adalah sebagai berikut :

1. Dataset yang digunakan dalam penelitian ini merupakan data hiperspektral tutupan lahan yang diperoleh dari sensor pesawat tanpa awak yakni dataset *Pavia Center*.
2. Dataset telah dinormalisasi dengan validasi *groundtruth* (peta kebenaran).

1.5. Manfaat Penelitian

Manfaat penelitian ini adalah sebagai berikut :

1. Kerangka kerja dapat diimplementasikan kembali sebagai referensi dalam penelitian lebih lanjut mengenai klasifikasi citra hiperspektral.
2. Mengatasi masalah dalam klasifikasi citra hiperspektral.
3. Mengetahui performa serta efektivitas metode *Regularized Hybrid CNN* dan perbandingan dengan CNN konvensional lainnya pada klasifikasi citra hiperspektral tutupan lahan.

1.6. Sistematika Penulisan

Dalam penelitian skripsi ini, peneliti menggunakan penelitian yang sistematis dan terbagi menjadi lima bab, berikut sistematika penulisan skripsi secara garis besar dari setiap bab :

BAB I PENDAHULUAN

Bab ini membahas latar belakang, tujuan, rumusan masalah, batasan masalah, manfaat, hipotesis dan sistematika penulisan yang mendasari penelitian ini.

BAB II TINJAUAN PUSTAKA

Pada bab ini berisikan teori-teori, tinjauan pustaka serta penelitian terdahulu yang berhubungan dengan penelitian, digunakan sebagai bahan pendukung dari penulisan skripsi ini.

BAB III METODOLOGI PENELITIAN

Bab ini memuat waktu dan tempat penelitian, alat dan bahan yang digunakan selama penelitian, serta penjelasan secara bertahap dan terperinci tentang metodologi yang digunakan untuk menyelesaikan proposal skripsi ini.

BAB IV HASIL DAN PEMBAHASAN

Berisikan proses proses pengolahan data yang digunakan dalam penelitian serta analisis dan pembahsan dari data-data hasil pengukuran dalam penelitian.

BAB V KESIMPULAN

Bab ini mencakup kesimpulan dari penelitian yang telah dilakukan dan menjawab tujuan dari penelitian ini serta berisikan saran untuk pengembangan penelitian lebih lanjut.

II. TINJAUAN PUSTAKA

2.1. Penelitian Terkait

Pada penelitian dengan judul *1D Convolutional Neural Networks for Hyperspectral Image Classification* oleh Feng et al. (2019), peneliti menggunakan tiga dataset hyperspectral, yaitu *Pavia University*, *Pavia Center*, dan *Salinas*. Peneliti menggunakan arsitektur 1D CNN dengan beberapa *layer* konvolusi, *max pooling*, dan *fully connected*. Data di-*preprocessing* dengan *mean removal* dan normalisasi. Hasil akurasi yang didapatkan dari masing masing dataset adalah 96,21%, 95,56% dan 96% [11].

Penelitian dengan judul *A Hyperspectral Image Classification Method Based on Stacked 2D Convolutional Neural Networks* oleh Chen et al. (2019) memperkenalkan metode baru untuk klasifikasi citra hiperspektral dengan menggunakan *stacked 2D Convolutional Neural Networks* (CNN). Metode ini menggabungkan fitur spasial dan spektral dari citra hiperspektral dengan cara mengekstraksi fitur dari masing-masing citra pada lapisan pertama CNN dan kemudian menggabungkannya di lapisan kedua CNN. Penelitian ini menggunakan dataset *Indian Pines* yang memiliki 224 hiperspektral *band* dan memiliki 16 kelas. Hasil akurasi dari penelitian ini adalah 96,56% [12].

Ma et al. (2020) mengusulkan metode klasifikasi citra hiperspektral berbasis 3D CNN menggunakan strategi penggabungan fitur baru. Pendekatan ini melibatkan ekstraksi fitur dari setiap spektrum citra hiperspektral dalam tiga dimensi (x, y, dan spektral) dan kemudian menggabungkan fitur-fitur tersebut dengan menggunakan metode fusi fitur yang inovatif. Kemudian, fitur-fitur tersebut diberikan pada

jaringan saraf konvolusi tiga dimensi untuk melakukan klasifikasi citra hiperspektral. Metode ini dievaluasi pada tiga dataset hiperspektral, yaitu *Pavia University*, *Indian Pines*, dan *Kennedy Space Center*. Akurasi klasifikasi tertinggi yang dicapai adalah 96,94% pada dataset *Pavia University*. Untuk dataset *Indian Pines*, metode ini mencapai akurasi sebesar 94,94%, sedangkan untuk dataset *Kennedy Space Center*, akurasinya adalah 96,85% [13].

Saeed et al (2021) mengusulkan penggunaan metode klasifikasi citra hiperspektral menggunakan *Hybrid 3D-2D Convolutional Neural Networks (CNN)*. *Hybrid 3D-2D CNN* merupakan pengembangan dari metode 2D CNN dan memiliki kemampuan dalam mempelajari fitur-fitur citra secara spasial dan spektral. Penelitian ini melakukan eksperimen pada beberapa dataset hiperspektral dan membandingkan hasilnya dengan metode klasifikasi lainnya, seperti SVM dan 2D CNN. Hasil eksperimen menunjukkan bahwa metode *Hybrid 3D-2D CNN* dapat memberikan performa yang lebih baik dalam klasifikasi citra hiperspektral dibandingkan dengan metode lainnya. *Average Accuracy* untuk *Indian Pines* sebesar 97% [14].

Pada Penelitian Muhammad Ahmad et al (2021) mengusulkan teknik regularisasi *entropy-based* dalam mengklasifikasi citra hiperspektral dan juga menggunakan teknik *smoothing* dalam klasifikasinya serta membandingkan dengan model CNN lainnya seperti *alexnet* dan 2D CNN. Hasil akurasi yang dihasilkan cukup tinggi yakni 98% pada dataset *Indian Pines* [15].

Berikut ini merupakan sebuah tabel mengenai klasifikasi citra hiperspektral yang digunakan untuk memahami tutupan lahan dalam periode waktu yang meliputi tahun penelitian dari 2019 hingga 2021. Penelitian ini mencakup sejumlah metode yang telah digunakan untuk mencapai pemahaman yang lebih mendalam mengenai karakteristik tutupan lahan. Semua temuan dan informasi relevan terkait penelitian ini tersaji dalam Tabel 2.1 Penelitian Terkait. Hal ini menjadi sumber utama referensi untuk pemahaman lebih lanjut mengenai topik ini dan sekaligus sebagai acuan esensial yang memberikan wawasan dan panduan bagi para peneliti dan praktisi yang ingin mengeksplorasi lebih dalam dan mendalami topik ini.

Tabel 2.1 Penelitian Terkait

No	Peneliti	Judul	Tahun	Metode	Hasil Akurasi (%)
1	Cheng et al	<i>A Novel SVM-Based Method for Hyperspectral Image Classification with Limited Samples</i>	2019	SVM	96,7%
2	Feng et al	<i>1D Convolutional Neural Networks for Hyperspectral Image Classification</i>	2019	1D CNN	96,1
3	Chen et al	<i>A Hyperspectral Image Classification Method Based on Stacked 2D Convolutional Neural Networks</i>	2019	2D CNN	96,56%
4	Me et al	<i>A 3D Convolutional Neural Network with new feature fusion strategy for hyperspectral image classification</i>	2020	3D CNN	96,85%
5	Saeed et al	<i>Hyperspectral Image Classification Using a Hybrid 3D-2D Convolutional Neural Networks</i>	2021	Hybrid CNN	97%
6	Ahmad, et al	<i>3D/2D regularized CNN feature hierarchy for Hyperspectral image classification</i>	2021	Regularized Hybrid CNN	98%

Pada penelitian terkait dapat disimpulkan bahwa tingkat akurasi yang dihasilkan sudah optimal yakni diatas 95%, namun berdasarkan kajian dari penelitian tersebut masih terdapat *research gap* dalam mengklasifikasi citra hiperspektral tutupan lahan dengan sampel terbatas, salah satu *gap* yang ditemukan ialah masih belum adanya teknik untuk mengatasi masalah *Overfitting* dan *Over Confidence* yang baik pada klasifikasi citra hiperspektral tutupan lahan. Pada penelitian *3D/2D regularized CNN feature hierarchy for Hyperspectral image classification* oleh Ahmad et al. Telah ditemukan teknik untuk mengatasi masalah ini dengan menggunakan entropy-based, namun pada kenyataannya *entropy-based* ini memiliki kompleksitas komputasi yang tinggi sehingga dapat mengakibatkan lamanya proses training dan juga mahalnya biaya komputasi dikarenakan kompleksitas model tersebut [15].

Selain belum terselesaikannya masalah *Over Confident* dengan baik, pada penelitian terkait juga masih terdapat interpretabilitas yang kurang hal ini disebabkan oleh penggunaan model yang kompleks dan memiliki banyak parameter sehingga sulit untuk diinterpreatsikan, seperti pada penelitian oleh Saeed et al (2020) dan Me et al (2020), pada penelitian tersebut hasil akurasi sudah tinggi dengan performa klasifikasi yang baik juga namun masih kurangnya interpretabilitas dalam *Hybrid CNN* yang disebabkan oleh kompleksitas arsitektur model dan kurangnya transparansi dalam proses ekstraksi fitur [16].

State-of-the-art pada penelitian ini adalah dengan mengembangkan metode CNN konvensional menggunakan metode *Regularized Hybrid CNN* dengan Optimasi *Adaptive Moment Estimation* (ADAM). Penelitian ini juga membandingkan performa model dengan CNN konvensional dengan *hyperparameters* yang berbeda, untuk mengetahui pengaruh performa klasifikasi citra hiperspektral dan bagaimana pengaturannya dapat dioptimalkan untuk mencapai performa terbaik. Pada penelitian ini juga dapat mengukur seberapa baik metode *Regularized Hybrid CNN* dalam memperbaiki performa klasifikasi citra hiperspektral dibandingkan dengan CNN konvensional, serta dapat menganalisis apakah teknik regularisasi yang digunakan dapat mengurangi permasalahan klasifikasi hiperspektral seperti underfitting atau *overfitting*.

Overfitting terjadi ketika model pembelajaran mesin bekerja dengan sangat baik pada data pelatihan, seperti dalam kasus kita yang dapat memprediksi hasil resume dengan akurasi 99% pada 10.000 data pelatihan. Namun, saat model ini diuji pada data yang berbeda, kinerjanya menjadi buruk karena model terlalu fokus pada detail-detail kecil dari data pelatihan dan gagal untuk menangkap pola umum yang sebenarnya. Ini seperti jika model belajar menghafal daripada memahami, sehingga ia tidak dapat beradaptasi dengan baik pada situasi baru [17].

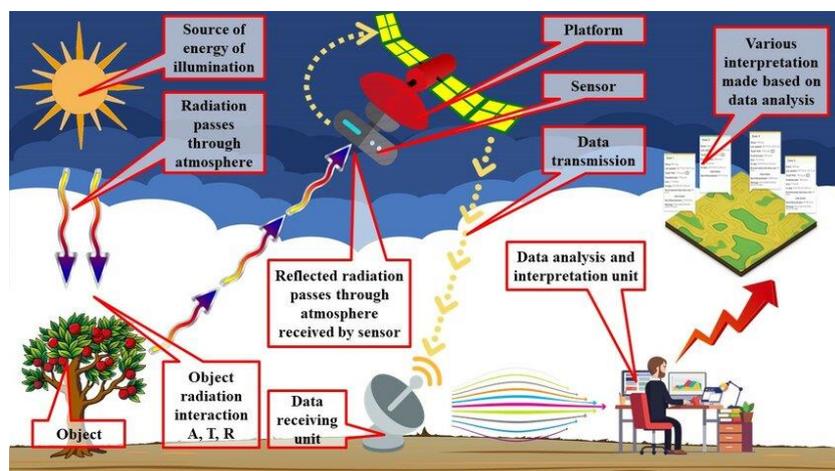
Pada penelitian ini juga akan menggunakan usulan teknik regularisasi seperti penggabungan antara *drop out regularization* dan juga *L2 Regularization* regularization. Hal ini digunakan tentu untuk mencegah terjadinya masalah pada klasifikasi khususnya yakni *overfitting* atau *over confidence classification*. Optimasi Adam pada penelitian ini digunakan untuk mengetahui efektifitas training dalam proses klasifikasi data, sehingga dapat mengukur tingkat keefektifan *Regularized Hybrid CNN* dengan CNN konvensional. Untuk mengatasi masalah *Interpretability*, penelitian ini akan menggunakan model dengan tingkat kompleksitas yang rendah serta membandingkan hasil akurasi secara keseluruhan dengan metode CNN konvensional. Berikut merupakan roadmap dari penelitian ini ditampilkan pada gambar 2.1.



Gambar 2.1 Roadmap Penelitian

2.2. Penginderaan Jauh

Penginderaan jauh adalah teknik pengambilan data/informasi dari suatu objek, daerah atau fenomena yang terletak di permukaan bumi menggunakan sensor yang terletak pada pesawat terbang, satelit, atau balon udara. Teknik ini banyak digunakan dalam berbagai aplikasi seperti pemantauan lingkungan, pemetaan tanah, pemantauan cuaca, pengelolaan sumber daya alam, dan lainnya [18]. Penginderaan jauh menurut Badan Standardisasi Nasional (BSN) atau SNI 7642:2010 adalah "Pengukuran karakteristik suatu objek dengan cara tidak langsung tanpa melakukan kontak fisik antara pengukur dan objek yang diamati, menggunakan sensor yang diletakkan di atas wahana udara atau permukaan bumi". Definisi ini mencakup penggunaan pesawat udara, satelit, dan sensor jauh untuk mengukur dan memperoleh informasi tentang bumi dan objek di permukaannya [19]. Pengamatan ini dilakukan menggunakan alat yang merekam pantulan gelombang elektromagnetik (cahaya) oleh permukaan bumi. Dalam kehidupan sehari-hari, kita juga menggunakan system penginderaan jauh, namun mata manusia memiliki keterbatasan spektrum elektromagnetik yang dapat ditangkap yakni sekitar 400-700 nanometer, yang mencakup warna-warna dalam spektrum warna seperti merah, jingga, kuning, hijau, biru, nila, dan ungu [20]. Pada sistem indera, berbagai macam alat dan perangkat digunakan untuk membuat gelombang elektromagnetik di luar rentang tersebut dapat dilihat oleh mata manusia *terutama near infrared, middle infrared, thermal infrared* dan gelombang mikro (radar). Gambar 2.1 Menunjukkan prinsip cara kerja dari penginderaan jauh.

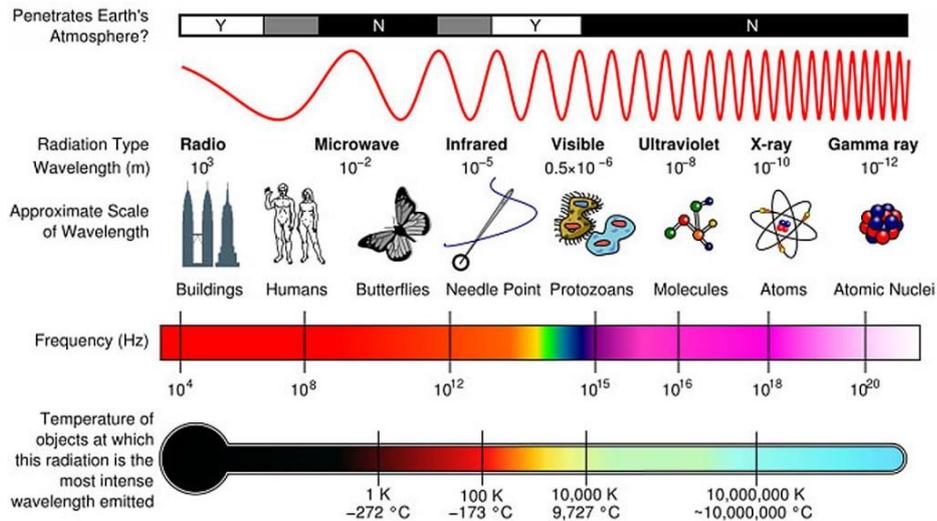


Gambar 2.2 Prinsip Cara Kerja Penginderaan Jauh [21]

Pada gambar di atas menunjukkan bagaimana penginderaan jauh dapat digunakan untuk memperoleh informasi mengenai benda atau fenomena di permukaan bumi dengan data yang dihasilkan oleh sensor. Proses tersebut yakni Sumber energi, misalnya sinar matahari, menghasilkan energi elektromagnetik (EM) yang dipancarkan ke arah permukaan bumi. Energi EM yang mencapai permukaan bumi kemudian diserap atau dipantulkan oleh benda di permukaan bumi tersebut. Radiasi yang dipantulkan oleh benda di permukaan bumi kemudian di deteksi oleh sensor di atas pesawat atau satelit yang berada di atasnya. Data yang dihasilkan oleh sensor kemudian diproses untuk menghasilkan citra atau informasi lain yang berguna, seperti peta suhu, tutupan lahan, kandungan air, dan sebagainya [21].

2.3. Spektrum Elektromagnetik

Secara umum spektrum elektromagnetik adalah rentang panjang gelombang atau frekuensi dari semua bentuk radiasi elektromagnetik, yang mencakup radiasi sinar gamma, sinar-X, ultraviolet, cahaya tampak, inframerah, gelombang radio, dan lain sebagainya. Spektrum elektromagnetik diperlihatkan secara berurutan, dari panjang gelombang terpendek ke terpanjang atau dari frekuensi tertinggi ke terendah [22]. Spektrum elektromagnetik memiliki variasi warna yang berbeda, yang tergantung pada temperatur sumber objeknya. Panjang gelombang dari radiasi elektromagnetik akan semakin sempit/pendek seiring dengan peningkatan energi yang dihasilkan, dan sebaliknya, semakin rendah energi yang dihasilkan maka gelombang akan semakin luas. Spesifikasi spektrum elektromagnetik yang tersaji pada Gambar 2.3 adalah informasi yang krusial dan penting untuk pemahaman lebih lanjut mengenai sifat dan karakteristik spektrum elektromagnetik. Gambar ini memberikan pandangan visual yang jelas tentang rentang gelombang elektromagnetik, serta area di mana spektrum ini digunakan dan diaplikasikan. Penting untuk dicatat bahwa spesifikasi spektrum elektromagnetik yang terdokumentasikan dalam Gambar 2.3 memiliki peran sentral dalam pemahaman spektrum elektromagnetik secara keseluruhan. Berikut merupakan spesifikasi spektrum elektromagnetik yang ditunjukkan pada Gambar 2.3 Ilustrasi Spektrum Elektromagnetik.



Gambar 2.3 Ilustrasi Spektrum Elektromagnetik [23]

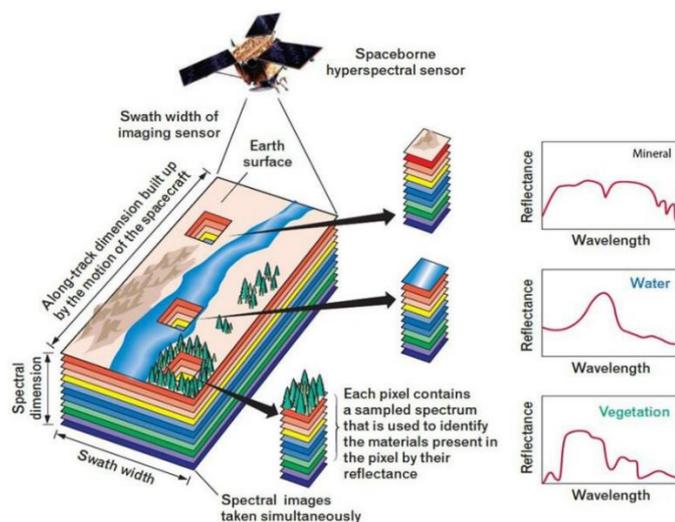
Radiasi elektromagnetik dapat diukur melalui frekuensi, panjang gelombang, dan energi. Penggunaan satuan yang tepat tergantung pada jenis spektrum yang diamati. Misalnya, untuk penelitian spektrum gelombang radio, satuan yang digunakan adalah frekuensi yang diukur dalam *Hertz* (Hz), sedangkan untuk spektrum sinar-X hingga sinar gamma, satuan yang digunakan adalah energi dalam satuan elektron volt (eV). Radiasi elektromagnetik dapat merambat tanpa memerlukan media sebab dapat merambat melalui ruang hampa.

2.4. Penginderaan Jauh Hiperspektral

Penginderaan jauh hiperspektral adalah suatu teknologi yang memanfaatkan spektrum elektromagnetik untuk memperoleh informasi tentang suatu objek atau wilayah dengan resolusi spektral yang tinggi. Teknologi ini mengacu pada pengumpulan data dari suatu objek atau wilayah dalam beberapa *band* spektral yang berdekatan secara terus-menerus. Data tersebut kemudian diolah dengan menggunakan algoritma klasifikasi untuk mengidentifikasi kandungan material atau benda-benda di permukaan bumi [24]. Konsep hiperspektral menggunakan sensor untuk merekam informasi reflektansi atau emisivitas benda atau permukaan pada berbagai spektrum atau pita gelombang yang luas, mulai dari ultraviolet

hingga inframerah. Teknologi ini memungkinkan penggunaan lebih dari 100 pita gelombang yang berbeda dan memberikan informasi spektral yang sangat detail tentang objek yang diamati [25].

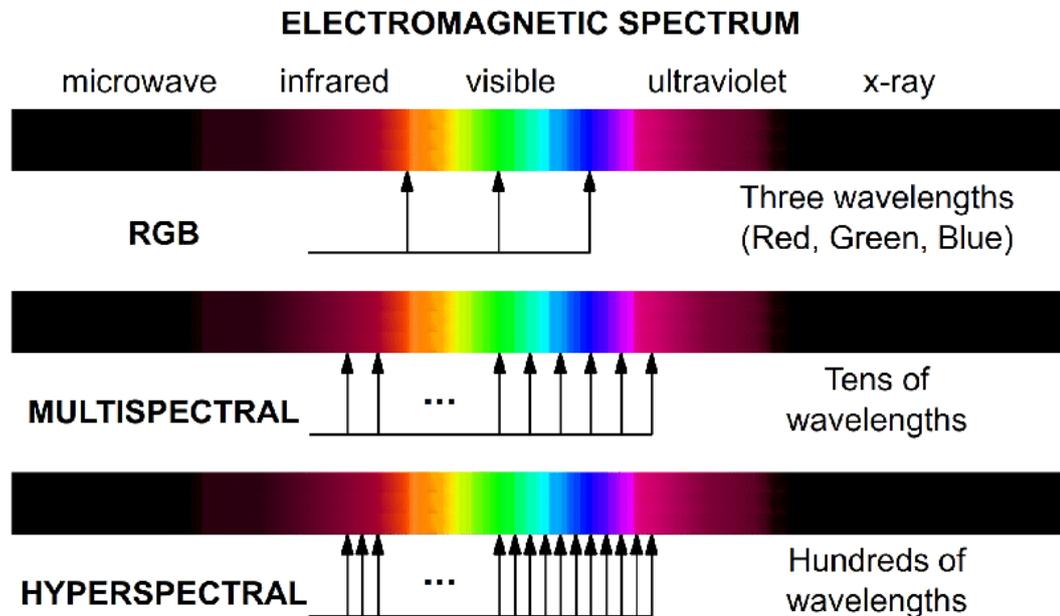
Citra hiperspektral merupakan pengembangan dari sensor multispektral yang memiliki kemampuan untuk merekam dan memetakan permukaan bumi dengan menggunakan rentang spektrum elektromagnetik yang lebih luas dan lebih terperinci. Pada citra hiperspektral, setiap spektrum elektromagnetik disusun dalam bentuk tumpukan gambar dua dimensi, sehingga membentuk kubus data yang terdiri dari beberapa lapisan. Setiap lapisan mewakili satu band spektral dengan panjang gelombang yang berbeda-beda. Dengan demikian, citra hiperspektral dapat memberikan informasi yang lebih detail dan kompleks mengenai objek atau permukaan yang diamati [26].



Gambar 2.4 Konsep Hiperspektral [27]

Konsep pencitraan hiperspektral. Pada setiap piksel direkam pengukuran spektral reflektansi, yang dapat diinterpretasikan untuk mengidentifikasi materi yang ada di dalamnya. Spektrometer atau sensor hiperspektral dapat dipasang pada platform udara atau luar angkasa [27]. Citra konvensional menggunakan spektrum tampak (*visible spectrum*) *Red Green Blue* (RGB), sedangkan citra hiperspektral memperluas spektrum yang digunakan dari citra konvensional dan citra multispektral. Spektrum yang digunakan pada citra hiperspektral meliputi *Visible*

Near Infrared (VNIR), Near Infrared (NIR), Thermal Infrared (TIR), Shortwave Infrared (SWIR), Midwave Infrared (MIR), dan Longwave Infrared (LWIR). Berikut merupakan perbandingan spektrum pada citra RGB, Multispektral dan Hiperspektral yang ditunjukkan pada gambar 2.4.



Gambar 2.5 Elektromagnetik Spektrum Citra RGB, Multispektral dan Hiperspektral [28].

Pemanfaatan citra hiperspektral sudah dilakukan di berbagai bidang penginderaan jauh, termasuk diantaranya evaluasi pengelolaan lahan, tata ruang wilayah, kebutuhan pertanian, analisis dan prediksi lingkungan, pemantauan iklim dan bidang lainnya. Pemanfaatan citra hiperspektral telah merambah berbagai ranah dalam penginderaan jauh. Bidang-bidang ini mencakup evaluasi pengelolaan lahan, perencanaan tata ruang wilayah, pertanian yang memerlukan informasi yang sangat rinci, analisis serta prediksi lingkungan, pemantauan iklim yang sangat relevan, serta banyak bidang lainnya. Dalam konteks ini, Tabel 2.1 menjadi sumber informasi utama yang memaparkan jenis-jenis citra hiperspektral beserta spesifikasinya berdasarkan sensor yang digunakan berdasarkan sensor dan spesifikasinya dapat dilihat pada Tabel 2.1. Jenis Sensor Citra Hiperspektral

Tabel 2.1 Jenis Sensor Citra Hiperspektral

Sensor Satelit	Pabrik	Jumlah Band	Selang Spektral
FTHSI on <i>MightySat</i> II	<i>Air Force Research Lab</i>	256	0,35 – 1,05 μm
<i>Hyperion on EO-1</i>	<i>NASA Goddard Space Flight Center</i>	220	0,4 – 2,5 μm
Sensor Pesawat	Pabrik	Jumlah Band	Selang Spektral
AVIRIS (<i>Airborne Visible Infrared Imaging Spectrometer</i>)	<i>NASA Jet Propulsion Lab</i>	224	0,4 – 2,5 μm
HYDICE (<i>Hyperspectral Digital Imagery</i>)	<i>Naval Research Lab</i>	210	0,4 – 2,5 μm
PROBE-1 Earth Search science Inc.	-	128	0,4 – 2,5 μm
CASI (<i>Compact Airborne Spectrographic Imager</i>)	<i>ITRES Research Limited</i>	Up – 228	0,4 – 1,0 μm
<i>HyMap</i>	<i>Integrated Spectronics</i>	100 – 200	<i>Visible – Thermal Infrared</i>
AISA (<i>Airborne Imaging Spectrometer</i>)	<i>Spectral Imaging</i>	Up – 228	0,43 – 1,0 μm

2.5. Tutupan Lahan

Tutupan lahan mengacu pada jenis dan kondisi tanah, air, atau vegetasi yang menutupi permukaan bumi. Tutupan lahan merupakan kenampakan material yang menutupi permukaan bumi dan tidak mengacu pada penggunaan secara komersil, dapat berupa vegetasi, permukaan air, ataupun tanah kosong [18]. LCCS (*Land Cover Classification System*) adalah suatu sistem klasifikasi tutupan lahan yang digunakan untuk menggambarkan tutupan lahan pada suatu wilayah. Sistem ini dikembangkan oleh FAO (*Food and Agriculture Organization*) untuk keperluan pemantauan dan pemetaan tutupan lahan secara global. LCCS membagi tutupan lahan menjadi 22 kelas utama yang terdiri dari 92 kelas detil. Setiap kelas detil didefinisikan dengan menggunakan kombinasi kriteria morfologi, struktur, penggunaan dan dinamika lahan. LCCS banyak digunakan dalam bidang penginderaan jauh dan pemantauan lingkungan untuk menghasilkan informasi mengenai perubahan tutupan lahan dan penggunaan lahan yang terjadi di suatu wilayah dalam jangka waktu tertentu. Selain itu, LCCS juga dapat digunakan sebagai acuan dalam pembuatan peta tutupan lahan secara global [29].

Pembagian kelas atau klasifikasi kelas pada tutupan lahan harus memenuhi beberapa karakteristik sebagai berikut [30].

1. Tersedia dalam format yang sesuai dan mudah digunakan oleh pengguna.
2. Akurasi klasifikasi yang tinggi, dengan tingkat kesalahan yang rendah.
3. Resolusi spasial dan spektral yang memadai untuk tujuan yang diinginkan.
4. Memperhitungkan heterogenitas dan keragaman tutupan lahan.
5. Memperhitungkan variasi dalam waktu dan ruang.
6. Bersifat terbuka dan dapat diakses untuk pembaruan dan pengembangan lebih lanjut.

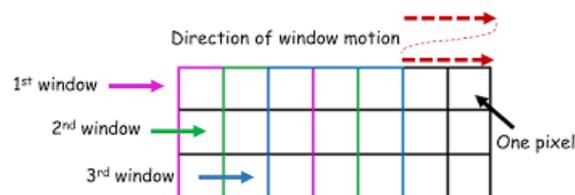
Pada penelitian ini dataset dan *Pavia* diklasifikasikan menggunakan sistem klasifikasi *Corine Land Cover* (CLC), yang dikembangkan dari sistem klasifikasi LCCS (*Land Cover Classification System*). Hal ini memungkinkan dataset *Indian*

Pines untuk diintegrasikan dengan data tutupan lahan global dan digunakan untuk menghasilkan produk tutupan lahan global (FAO, 1996).

Sistem klasifikasi CLC (*Corine Land Cover*) yang digunakan pada dataset *Indian Pines* adalah sistem klasifikasi yang dikembangkan oleh European Environment Agency untuk mengklasifikasikan tutupan lahan di Eropa. Sistem klasifikasi CLC ini terdiri dari 44 kategori tutupan lahan yang terbagi menjadi 3 level hierarki. Level pertama terdiri dari 5 kategori besar, yaitu tutupan lahan pertanian, hutan, lahan basah, tutupan lahan bukan pertanian, dan tutupan lahan terbangun. Level kedua terdiri dari 15 kategori sub, sedangkan level ketiga terdiri dari 44 kategori yang lebih detail. Pada dataset *Indian Pines* dan *Salinas*, sistem klasifikasi CLC digunakan untuk mengklasifikasikan tutupan lahan yang terdapat pada citra hiperspektral yang diambil menggunakan sensor AVIRIS. Klasifikasi tutupan lahan pada dataset ini bertujuan untuk mengidentifikasi jenis tanaman atau vegetasi yang terdapat di lahan tersebut [31].

2.6. Praproses Data

Praproses data adalah serangkaian tahapan atau prosedur yang dilakukan untuk mempersiapkan data mentah sebelum data tersebut dapat digunakan untuk analisis lebih lanjut. Praproses data dapat meliputi beberapa tahapan seperti pemrosesan citra, pembersihan data, transformasi data, dan normalisasi data. Tujuan dari praproses data adalah untuk menghilangkan *noise*, kesalahan, atau anomali pada data, sehingga memungkinkan analisis yang lebih akurat dan valid. Pada penelitian ini menggunakan salah satu teknik pra proses data yakni *patch extraction* dengan menggunakan teknik *sliding window*.



Gambar 2.6 Sliding Window

Sliding window patch extraction adalah teknik pra pemrosesan data yang digunakan dalam klasifikasi citra hiperspektral. Teknik ini melibatkan pemotongan citra hiperspektral menjadi potongan-potongan kecil yang disebut "*patch*" atau "jendela geser", di mana setiap *patch* dianggap sebagai citra kecil dengan jumlah spektrum yang lebih sedikit. Setelah itu, setiap *patch* diekstraksi fitur-fiturnya dan digunakan sebagai *input* untuk model klasifikasi.

Proses *sliding window patch extraction* dapat dijelaskan sebagai berikut; Pertama, ukuran jendela (*window size*) ditentukan. Ukuran jendela harus dipilih dengan hati-hati, karena terlalu besar akan memperkenalkan kelebihan parameter dan terlalu kecil akan memperkenalkan *underfitting*. Kemudian, jendela diposisikan pada citra hiperspektral dan dijalan secara berulang-ulang dengan menggeser jendela ke kiri dan ke kanan secara horizontal, dan atas dan bawah secara vertikal. Ini menghasilkan sejumlah *patch* yang bersinggungan satu sama lain, dengan beberapa *patch* yang tumpang tindih. Setiap *patch* kemudian dianggap sebagai citra kecil yang berdiri sendiri dengan jumlah spektrum yang lebih sedikit dari citra hiperspektral asli. Kemudian, fitur-fitur diekstraksi dari setiap *patch*. Beberapa fitur umum yang diekstraksi termasuk statistik spektral, seperti *mean*, *standard deviation*, dan *skewness*. Fitur-fitur lain seperti indeks rasio juga dapat digunakan. Setiap *patch* dan label yang sesuai dikumpulkan sebagai *input* untuk model klasifikasi.

2.7. Klasifikasi Citra Hiperspektral

Klasifikasi citra hiperspektral adalah proses mengelompokkan piksel dalam citra hiperspektral ke dalam kelas-kelas yang berbeda, berdasarkan informasi spektral yang terkandung dalam citra tersebut. Klasifikasi ini dapat dilakukan dengan menggunakan berbagai algoritma, seperti SVM, *Random Forest*, dan *k-Nearest Neighbor*. Tujuan dari klasifikasi citra hiperspektral adalah untuk mengidentifikasi pola atau fitur-fitur dalam citra yang dapat digunakan untuk mengambil informasi yang relevan dan berguna dari suatu area tertentu [24].

Secara umum untuk melakukan klasifikasi citra hiperspektral, langkah pertama adalah melakukan pra-pemrosesan data, seperti reduksi dimensi, normalisasi, dan penghapusan noise. Kemudian, fitur-fitur spektral yang relevan diekstraksi dari citra menggunakan teknik seperti *Principal Component Analysis* (PCA) atau *Independent Component Analysis* (ICA). Setelah itu, algoritma klasifikasi yang sesuai digunakan untuk mengklasifikasikan piksel-piksel dalam citra ke dalam kelas-kelas yang berbeda. Penelitian ini akan mengembangkan model CNN dengan metode *Hybrid CNN* dengan teknik regularisasi berserta optimasi adam, selain itu pada penelitian ini juga akan membandiingkan dengan metode/model CNN konvensional seperti CNN, 2D CNN dan 3D CNN.

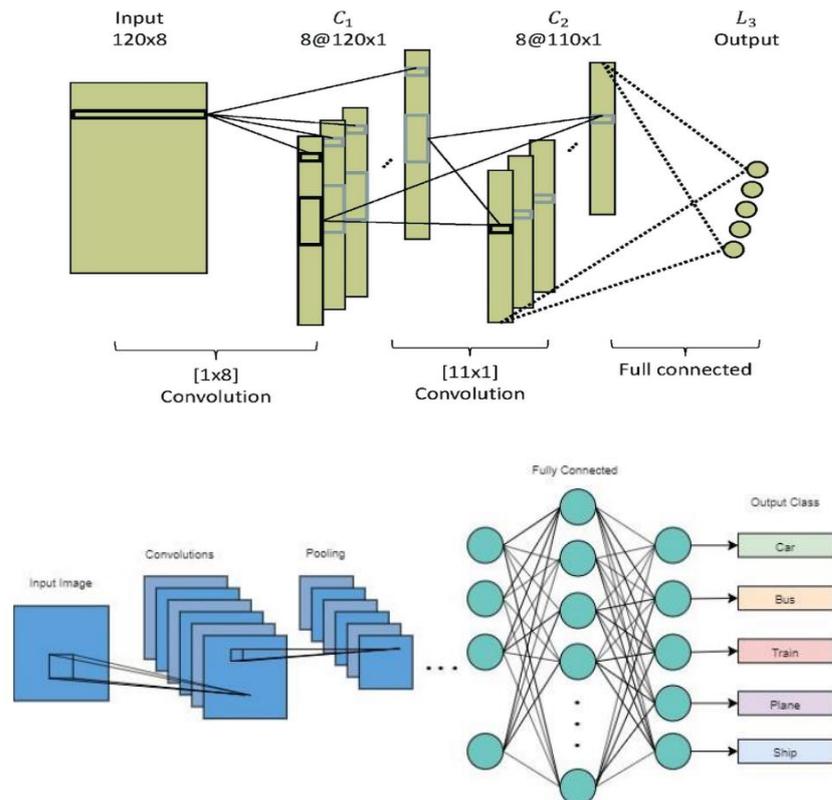
2.7.1. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) pertama kali diperkenalkan pada tahun 1980-an oleh Yann LeCun dan rekan-rekannya, dengan fokus pada pengenalan karakter pada dokumen tertulis. Namun, pada saat itu, CNN masih terbatas pada pemrosesan citra 2D yang relatif sederhana. Pada tahun 1998, Lecun dan rekan-rekannya memperkenalkan arsitektur CNN yang lebih kompleks dan berhasil mencapai tingkat keakuratan yang lebih tinggi dalam pengenalan karakter tulisan tangan. Kemudian pada tahun 2012, CNN menjadi sangat populer setelah arsitektur *AlexNet* memenangkan kompetisi *ImageNet*, sebuah tantangan besar dalam pengenalan gambar. *AlexNet* berhasil mengalahkan metode tradisional dengan tingkat kesalahan yang jauh lebih rendah dan memperkenalkan konsep penting seperti *dropout* dan *ReLU activation function* [32].

Convolutional Neural Network (CNN) adalah sebuah jenis arsitektur jaringan saraf tiruan yang biasa digunakan dalam pengolahan citra dan video. Arsitektur CNN memiliki lapisan konvolusi yang memungkinkan jaringan untuk secara efektif mengekstraksi fitur-fitur penting dari citra atau video secara hierarkis. CNN dikembangkan dari metode *Multi Layer Perceptron* (MLP) dan didesain untuk mengolah data 2 dimensi [33]. Metode CNN dirancang untuk mempelajari fitur hirarki dari tingkat rendah ke fitur tingkat tinggi secara otomatis.

2.7.2. Arsitektur CNN

Layer dalam arsitektur CNN memiliki susunan tiga dimensi, yaitu lebar (*width*), tinggi (*height*), dan kedalaman (*depth*). Kedalaman mengacu pada jumlah lapisan *filter* yang digunakan pada *layer* tersebut, dan biasanya diatur secara eksplisit oleh pengguna [33].



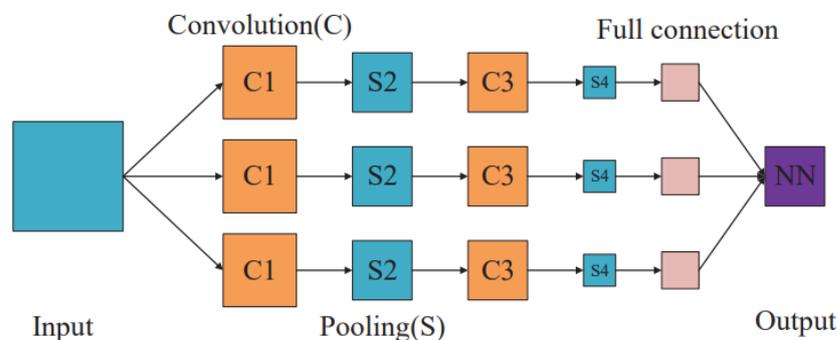
Gambar 2.7 Arsitektur CNN Secara Umum [34]

Secara umum, metode CNN terdiri dari dua tahap utama, yaitu tahap ekstraksi fitur pada awal arsitektur dan tahap klasifikasi. Tahap ekstraksi fitur terdiri dari beberapa *layer* dengan fungsi yang berbeda-beda dan saling terhubung. *Layer* yang terdapat pada tahap ini meliputi *layer konvolusi* dan *layer pooling*, yang bekerja untuk memproses *input* dan menghasilkan vektor yang akan digunakan pada tahap berikutnya. Pada tahap klasifikasi, terdapat beberapa *layer* yang masing-masing terdiri dari neuron yang terkoneksi secara penuh dengan *layer* lainnya. *Layer* ini

menerima vektor hasil ekstraksi fitur dan diolah seperti jaringan saraf untuk menghasilkan *output* berupa akurasi kelas untuk klasifikasi [35].

Metode CNN (*Convolutional Neural Network*) bekerja dengan melakukan operasi konvolusi pada setiap *layer* untuk mengekstrak fitur-fitur penting pada gambar. Proses ini dilakukan secara berulang pada setiap *layer* hingga diperoleh representasi yang semakin abstrak. Selanjutnya, hasil representasi tersebut akan diklasifikasikan menggunakan *layer fully connected*. Lebih rinci, CNN mengambil gambar sebagai *input* dan melewatkannya melalui serangkaian *layer*. Setiap *layer* terdiri dari neuron atau unit yang terhubung dengan unit pada *layer* sebelumnya. *Layer* konvolusi melakukan operasi konvolusi pada gambar *input* dengan sejumlah *filter* untuk menghasilkan fitur-fitur pada gambar. Kemudian, hasil dari operasi konvolusi tersebut akan melewati *layer* aktivasi seperti ReLU (*Rectified Linear Unit*) untuk menambahkan non-linearitas pada model. Setelah sejumlah *layer* konvolusi dan aktivasi, gambar akan dikurangi dimensinya menggunakan *layer pooling*, seperti *MaxPooling* atau *AveragePooling*. Hal ini dilakukan untuk mengurangi dimensi data dan mempercepat proses pelatihan. Setelah beberapa *layer* konvolusi dan *pooling*, hasilnya akan disampaikan ke *layer fully connected* yang melakukan klasifikasi. *Layer fully connected* menghubungkan setiap neuron di satu *layer* dengan semua neuron di *layer* berikutnya, dan *output* yang dihasilkan akan menjadi hasil prediksi [33].

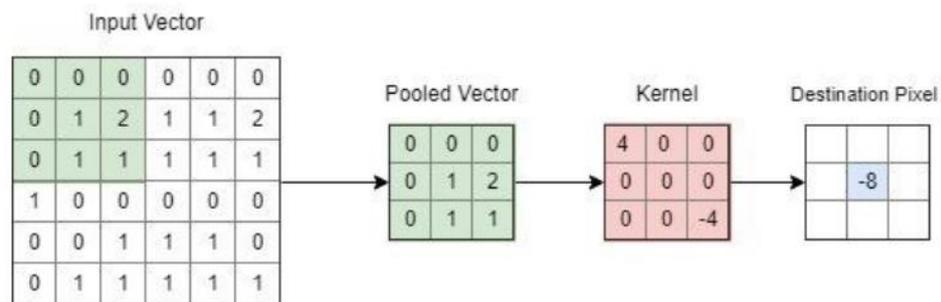
Secara umum CNN memiliki tiga *layer* utama yang saling terhubung, yaitu *convolutional layer*, *pooling layer* dan *fully connected layer* [36] :



Gambar 2.8 CNN Model Dengan *Convolution Layers*, *Pooling Layers* Dan *Full Connection Layer* [37]

1. Convolutional Layer

Secara umum, *convolutional layer* adalah blok utama dan sangat penting dalam operasi CNN. *Convolutional layer* memiliki parameter yang berupa set *filter* atau kernel yang bergerak secara horizontal dan vertikal pada *input* citra, dan berfungsi untuk mengekstraksi fitur dari *input* citra dan mempelajari representasi fitur yang dapat digunakan untuk klasifikasi atau tugas lainnya. Kernel ini dapat berukuran 3x3, 5x5, 7x7 sesuai dengan kebutuhan dan ditentukan dalam setting manual parameter CNN. Unit *Convolutional layer* terhubung secara lokal ke peta fitur pada *layer* sebelumnya melalui serangkaian bobot yang disebut bank *filter*. Pada tahap awal, bobot pada setiap kernel diinisialisasi secara acak untuk melakukan operasi konvolusi yang dilakukan dengan pembaruan berulang. Dalam proses ini, *convolutional layer* secara bertahap mempelajari dan mengekstraksi fitur yang relevan dari *input* citra.



Gambar 2.9 Proses Operasi Konvolusi CNN [38]

Operasi konvolusi dapat didefinisikan pada persamaan berikut:

$$v_{lj}^{xy} = f\left(\sum_m \sum_{h=0}^{H_j-1} \sum_{w=0}^{W_j-1} k_{ljm}^{hw} v_{(l-1)m}^{(x+h)(y+h)}\right) + b_{lj} \quad (2.1)$$

Dimana l merupakan *layer* yang dipertimbangkan, j adalah jumlah peta fitur pada *layer* ini. v_{lj}^{xy} adalah *output* dengan posisi (x,y) pada peta fitur ke j di *layer* l . b merupakan bias dan $f(\cdot)$ adalah fungsi aktivasi. m adalah indeks dari peta fitur di *layer* $(l-1)$ terhubung ke peta fitur. k_{ljm}^{hw} merupakan

nilai pada posisi dari kernel yang terhubung ke peta fitur ke j . H dan W adalah masing-masing ukuran kernel. Fungsi aktivasi ReLU adalah sebagai berikut:

$$f(x) = \text{ReLU}(x) = \begin{cases} x & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (2.2)$$

2. *Fully connected Layer*

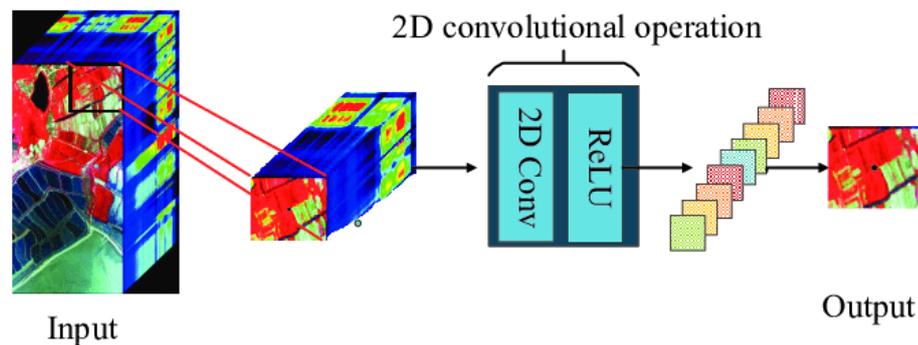
Fully connected layer adalah sebuah *layer* pada CNN yang menggunakan *Multi Layer Perceptron* (MLP) tradisional dan memiliki fungsi aktivasi *softmax* pada lapisan *output*. *Layer* ini menerima volume *input* dari *layer* sebelumnya seperti *convolution*, ReLU atau *pooling layer*. Seperti jaringan *feedforward* tradisional, *fully connected layer* juga menghasilkan vektor dimensi N , di mana N adalah jumlah kelas. Tujuannya adalah untuk menggunakan fitur-fitur tersebut dan melakukan klasifikasi citra ke dalam berbagai kelas berdasarkan data yang telah diinisialisasi saat proses *training*.

3. *Pooling Layer*

Pooling layer pada *Convolutional Neural Network* (CNN) adalah salah satu jenis *layer* yang berfungsi untuk mengurangi dimensi spasial dari *output* yang dihasilkan oleh *layer* sebelumnya (biasanya *convolutional layer*). Hal ini dilakukan dengan mengambil nilai maksimum atau rata-rata dari sekelompok nilai yang ditemukan pada area yang sama dari *input*. *Pooling layer* dapat membantu mengurangi jumlah parameter dalam model, mencegah *overfitting*, dan membuat model lebih invariant terhadap translasi kecil pada *input*. Ada beberapa jenis *pooling layer* yang umum digunakan, seperti *max pooling* yang memilih nilai maksimum dalam setiap area, dan *average pooling* yang mengambil rata-rata nilai dalam area tersebut. Kedua *layer* inilah yang paling umum digunakan pada arsitektur CNN [37].

2.7.3. Two Dimensional CNN

2D CNN (*Convolutional Neural Network*) adalah sebuah tipe arsitektur jaringan saraf tiruan yang digunakan khusus untuk memproses data berdimensi dua, seperti gambar dan citra. Arsitektur ini memiliki *layer-layer* yang khusus untuk mempelajari dan mengekstraksi fitur-fitur penting dari gambar atau citra, seperti *edges*, *corners*, dan *textures*, sehingga dapat digunakan untuk tugas-tugas seperti klasifikasi, segmentasi, dan deteksi objek pada gambar atau citra. Dalam 2D CNN, konvolusi dilakukan pada kedua dimensi (y dan x) dari gambar atau citra. Setiap *filter* (kernel) yang digunakan pada *layer* konvolusi memiliki dimensi 2D dan menggeser (*slide*) pada seluruh area gambar atau citra untuk menghasilkan *feature map* yang baru. Selanjutnya, dilakukan *pooling* pada *feature map* untuk mengurangi dimensi dan mengurangi *overfitting* [32]. Berikut merupakan arsitektur 2 dimensional CNN:



Gambar 2.10 Arsitektur 2D CNN [37].

Gambar di atas merupakan arsitektur sederhana 2D CNN yang didalamnya terdapat *2D convolutional operation* dengan *kernel size* (k) dan jumlah dari *feature maps* (m) pada setiap *convolutional layer* dari klasifikasi citra hiperspektral. Perbedaan utama antara 2D CNN dan CNN pada umumnya terletak pada strukturnya. CNN pada umumnya beroperasi pada data berdimensi tinggi, seperti gambar berwarna (RGB), sedangkan 2D CNN dirancang khusus untuk bekerja pada data berdimensi 2, seperti citra hitam putih atau *grayscale*. Selain itu, dalam 2D CNN, *filter* juga memiliki dimensi 2, yang digunakan untuk mengekstraksi fitur dari citra secara lokal. Konsep dasar dari 2D CNN sama dengan CNN pada umumnya, yaitu terdiri

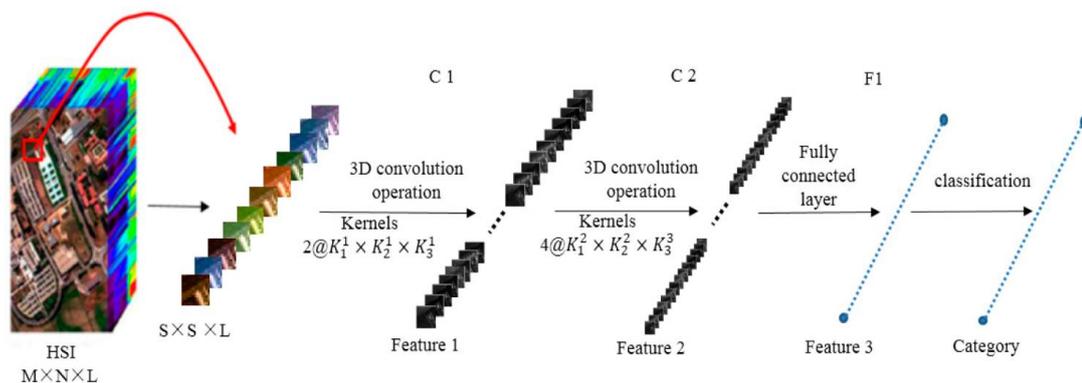
dari lapisan konvolusi, lapisan aktivasi, dan lapisan *pooling*. Namun, pada 2D CNN, lapisan konvolusi dan *pooling* diaplikasikan pada kedua dimensi citra. Citra hiperspektral dikonversi menjadi bentuk matriks dan masing-masing piksel dalam citra dianggap sebagai entitas data. Selanjutnya, 2D CNN digunakan untuk mempelajari fitur-fitur dari matriks piksel yang diberikan dan menghasilkan model klasifikasi [37].

2.7.4. Three Dimensional CNN

Penerapan metode 3D CNN pada umumnya digunakan dalam konteks pemrosesan video dan bertujuan untuk mengekstrak fitur dari dimensi spasial dan temporal. Untuk mencapai hal tersebut, proses konvolusi 3D diterapkan pada kubus fitur 3D untuk menghitung fitur spatiotemporal dari data *input* 3D. Secara umum, nilai pada posisi (x, y, z) pada kubus fitur ke- j pada lapisan ke- l diberikan oleh:

$$v_{ij}^{xy} = f\left(\sum_m \sum_{h=0}^{Hl-1} \sum_{w=0}^{Wl-1} \sum_{r=0}^{Rl-1} k_{ljm}^{hwr} v_{(l-1)m}^{(x+h)(y+w)(z+r)}\right) + b_{lj} \quad (2.3)$$

dimana Rl adalah ukuran kernel 3D sepanjang dimensi spektral, j adalah jumlah kernel di lapisan ini, dan k_{ljm}^{hwr} adalah nilai (h, w, r) dari kernel yang terhubung ke kubus fitur ke- m di lapisan sebelumnya. Berbeda dengan operasi konvolusi pada CNN standar yang berbentuk 2 dimensi, operasi konvolusi pada 3D CNN berbentuk 3 dimensi ditunjukkan pada Gambar 2.11.

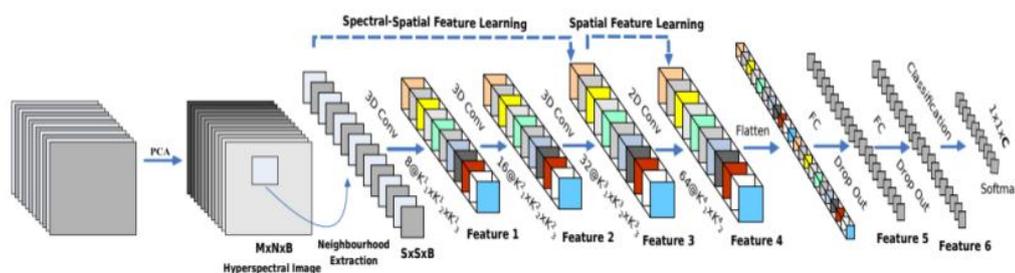


Gambar 2.11 Arsitektur 3D CNN [39].

Dalam klasifikasi hiperspektral, penggunaan operasi konvolusi 2D hanya melibatkan data *input* pada dimensi spasial, sementara operasi konvolusi 3D menggabungkan data *input* pada dimensi spasial dan dimensi spektral secara bersamaan. *Output* dari operasi konvolusi 2D selalu berdimensi 2D, terlepas dari apakah itu diterapkan pada data 2D atau data 3D. Jika operasi konvolusi 2D diterapkan pada data hiperspektral, informasi spektral yang signifikan dapat hilang, sementara operasi konvolusi 3D dapat mempertahankan informasi spektral dari data *input* hiperspektral, menghasilkan volume *output* yang sesuai dengan format HSI. Hal ini sangat penting untuk pengolahan HSI, yang mengandung informasi spektral yang sangat berharga [39].

2.7.5. Regularized Hybrid CNN

Penelitian ini mengusulkan metode algoritma *Regularized Hybrid CNN* dalam klasifikasi citra hiperspektral. Penggunaan metode 2D CNN dianggap tidak dapat mengoptimalkan eksploitasi fitur namun 2D CNN efektif dalam mengekstrak fitur spasial dalam citra, seperti tepi, tekstur, dan pola visual. Di sisi lain, metode 3D CNN memiliki parameter yang rumit dan memerlukan biaya komputasi yang tinggi namun 3D CNN dapat menangani data citra hiperspektral yang mencakup dimensi spektral selain dimensi spasial. Untuk mengatasi masalah ini, penelitian ini mengembangkan suatu metode hibrida yang menggabungkan CNN 3D dan CNN 2D. Tujuannya adalah untuk memperoleh fitur yang dapat membedakan dengan baik antara kelas citra, sambil tetap mengurangi kompleksitas parameter dan biaya komputasi pada CNN 3D. Arsitektur *Hybrid CNN* ditampilkan pada gambar 2.12.



Gambar 2.12 Arsitektur Hybrid CNN [39].

Pada arsitektur *HybridSN* di atas, digunakan dua *convolutional layer* yang berbeda, yaitu *convolutional layer* tiga dimensi (Conv3D) dan *convolutional layer* dua dimensi (Conv2D). Terdapat tiga Conv3D dan satu Conv2D serta dua *fully connected layer*. Pada metode ini tidak digunakan *pooling layer* untuk memperoleh representasi asli dari citra hiperspektral.

Metode *Hybrid* akan menggabungkan teknik 3D dan 2D CNN untuk memaksimalkan penggunaan dua fitur pada citra hiperspektral. Dengan memanfaatkan korelasi spasial dan spektral secara bersamaan, metode ini dapat mengekstrak fitur yang lebih diskriminatif dan meningkatkan spesifikasi kelas, sehingga menghasilkan akurasi yang lebih baik. Berbeda dengan CNN tunggal, metode ini mengekstrak fitur secara simultan. Usulan pada penelitian ini juga menggunakan penggabungan dua jenis *activation* yang berbeda serta dua jenis regularisasi yakni *dropout layer* dan *L2 Regularization* dengan dua jenis *optimizer*.

1. Leaky ReLU (Rectified Linear Unit)

Leaky ReLU (Rectified Linear Unit) adalah salah satu fungsi aktivasi yang digunakan pada *Convolutional Neural Network* (CNN). Fungsi ini dikembangkan sebagai alternatif dari ReLU untuk mengatasi masalah '*dying ReLU*' yang dapat terjadi pada lapisan dalam CNN, di mana beberapa neuron tidak lagi berkontribusi pada hasil akhir karena nilai keluarannya selalu bernilai nol. *Leaky ReLU* memiliki rumus matematis yang mirip dengan ReLU, namun jika nilai *inputnya* negatif, maka fungsi akan memberikan keluaran yang kecil namun positif. Dengan kata lain, *Leaky ReLU* memungkinkan nilai negatif tetap berkontribusi pada *output* CNN dan membantu mencegah terjadinya '*dying ReLU*' [40].

Leaky ReLU dapat dirumuskan melalui persamaan berikut :

$$f(x) = \max(ax, x) \quad (2.4)$$

Dimana x adalah nilai *input* ke neuron, dan a adalah nilai tetap yang biasanya diatur sangat kecil, seperti 0,01. Penggunaan *Leaky ReLU* pada CNN telah terbukti meningkatkan kinerja model pada beberapa kasus, terutama pada

dataset yang besar dan kompleks. Namun, seperti halnya fungsi aktivasi lainnya, pilihan *Leaky ReLU* juga tergantung pada jenis masalah yang sedang diselesaikan dan kinerja model yang diinginkan.

2. *Softmax Activation*

Softmax adalah fungsi aktivasi yang sering digunakan pada *Convolutional Neural Network* (CNN) untuk menghasilkan probabilitas *output* pada setiap kelas klasifikasi. Fungsi ini sangat cocok untuk digunakan pada klasifikasi multikelas, di mana suatu objek harus diklasifikasikan ke dalam salah satu dari beberapa kelas yang mungkin. *Softmax* bekerja dengan mengambil *input* dari lapisan terakhir pada CNN, kemudian menghasilkan distribusi probabilitas pada setiap kelas yang ada pada *output*. Fungsi *softmax* mengubah *output* dari neuron terakhir pada CNN menjadi probabilitas, sehingga jumlah *output* dari semua neuron di lapisan *output* sama dengan satu. Probabilitas pada setiap kelas yang dihasilkan oleh *softmax* kemudian dapat digunakan untuk menentukan kelas yang paling mungkin untuk suatu objek yang akan diklasifikasikan [33].

Fungsi *Softmax* dapat dirumuskan melalui persamaan matematis berikut

$$f(y_i) = \frac{e^{(y_i)}}{\sum e^{(y_j)}} \quad (2.5)$$

Dimana y_i adalah *input* pada neuron terakhir, dan j adalah indeks dari setiap neuron pada lapisan *output*. Dalam rumus ini, e adalah bilangan eksponensial (2.71828...), dan \sum adalah operator penjumlahan dari seluruh nilai *output* pada lapisan *output*. Penggunaan *softmax* pada CNN sangat berguna untuk meningkatkan akurasi pada klasifikasi multikelas. Fungsi ini juga memungkinkan CNN untuk menghasilkan probabilitas *output* pada setiap kelas, sehingga dapat digunakan untuk mengevaluasi tingkat kepercayaan model dalam melakukan klasifikasi pada setiap objek.

3. Adam *optimizer*

Adam *optimizer* merupakan salah satu algoritma optimasi yang sering digunakan pada *Convolutional Neural Network* (CNN) untuk mengoptimalkan nilai bobot dan bias pada jaringan. Adam *optimizer* adalah singkatan dari *Adaptive Moment Estimation*, yang menggabungkan dua teknik optimasi, yaitu *Adagrad* dan *RMSprop*, serta menambahkan metode momentum untuk meningkatkan kecepatan konvergensi. Pada dasarnya, Adam *optimizer* memperhitungkan gradien dari bobot dan bias pada setiap langkah iterasi. Algoritma ini juga menghitung dan menyimpan estimasi adaptif kedua momen gradien, yaitu *mean* dan *variance*, dari gradien pada setiap langkah iterasi. Estimasi ini akan digunakan untuk menyesuaikan laju pembelajaran pada setiap parameter, sehingga algoritma dapat mengatasi masalah laju pembelajaran yang terlalu kecil atau terlalu besar [33].

Optimizer ini disebut Adam karena menggunakan estimasi momen pertama dan kedua dari gradien untuk menyesuaikan tingkat pembelajaran untuk setiap bobot pada jaringan saraf. Nama Adam ini ini bukan singkatan dari sesuatu. Adam diusulkan sebagai teknik optimisasi stokastik yang paling efisien yang hanya membutuhkan gradien orde pertama di mana kebutuhan memori sangat sedikit. Sebelum Adam, banyak teknik optimisasi adaptif diperkenalkan seperti AdaGrad, RMSP yang memiliki kinerja baik dibandingkan SGD tetapi dalam beberapa kasus memiliki beberapa kelemahan seperti kinerja generalisasi yang lebih buruk daripada SGD dalam beberapa kasus. Jadi, Adam diperkenalkan yang lebih baik dalam hal kinerja generalisasi. Selain itu, dalam Adam, hiperparameter memiliki interpretasi yang intuitif dan karena itu membutuhkan penyesuaian yang lebih sedikit [41].

Cara kerja Adam Optimizer dalam klasifikasi citra hiperspektral dengan menggunakan CNN yakni pada tahap awal, arsitektur CNN diinisialisasi dengan lapisan konvolusi, penyearah, serta lapisan lain yang relevan untuk tugas klasifikasi citra hiperspektral. Selanjutnya, parameter-parameter Adam seperti tingkat pembelajaran, β_1 , dan β_2 diberi nilai awal untuk

memengaruhi adaptasi learning rate dan perhitungan momentum. Pelatihan dilakukan dalam beberapa iterasi (*epochs*) dengan langkah-langkah termasuk memuat data citra hiperspektral dalam *mini-batch* untuk mempercepat proses dan mencegah *overfitting*. Data *mini-batch* menjalani proses forward propagation melalui CNN, melibatkan konvolusi, aktivasi, penyetimbangan, dan lapisan-lapisan lain. Selanjutnya, dilakukan perhitungan *loss* antara hasil prediksi CNN dan label sebenarnya untuk mengukur performa model. Selama backward propagation, gradien dari *loss* terhadap parameter-parameter CNN dihitung, melibatkan semua lapisan dalam CNN. Akhirnya, parameter-parameter CNN diperbarui menggunakan algoritma Adam yang menggabungkan momentum gradien dan RMSprop untuk mengoptimalkan model.

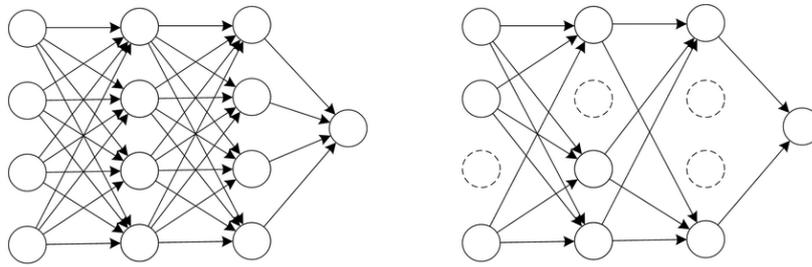
4. *Stochastic Gradient Descent Optimizer*

SGD (*Stochastic Gradient Descent*) merupakan salah satu algoritma optimasi yang signifikan dalam konteks penelitian klasifikasi citra hiperspektral. Algoritma ini berperan kunci dalam mencari parameter-optimal dalam model klasifikasi, dengan tujuan untuk meminimalkan fungsi objektif yang mengukur kesalahan prediksi model terhadap data pelatihan. Dalam konteks penelitian ini, *SGD Optimizer* berfungsi sebagai alat utama untuk mengoptimalkan model klasifikasi citra hiperspektral dengan mencari bobot-bobot yang dapat menghasilkan prediksi yang sesuai dan akurat dengan data pelatihan. Hal ini merupakan langkah penting dalam upaya meningkatkan akurasi dan generalisasi model yang relevan dengan domain klasifikasi citra hiperspektral [41].

5. *Dropout Regularization*

Untuk mencegah terjadinya *overfitting* pada jaringan CNN yang memiliki jutaan node neuron yang saling berkomunikasi dan harus melakukan banyak proses dalam waktu tertentu, dilakukan eliminasi acak beberapa set neuron tertentu. Set neuron tersebut tidak akan digunakan selama fase pembelajaran *forward pass* maupun *backward pass* dengan *backpropagation*, sehingga mengurangi kemungkinan *overfitting* pada jaringan. Teknik eliminasi neuron

ini disebut *dropout* [42]. Gambar 2.10 menunjukkan perbedaan antara jaringan standar dan jaringan yang menggunakan *dropout*.



Gambar 2.13 *Standard Neural Network* dan *Dropout Neural Network* [43]

Pada gambar di atas, Gambar (a) menunjukkan jaringan saraf biasa dengan dua lapisan tersembunyi, sementara gambar (b) menunjukkan jaringan saraf yang menggunakan *dropout*. Pada gambar (b), beberapa neuron aktivasi telah dihapus. Teknik ini dapat dengan mudah diimplementasikan pada model CNN dan dapat meningkatkan performa model dalam pelatihan serta mengurangi *overfitting* [42]. *Dropout rate* merupakan parameter pada Teknik *dropout* yang menentukan seberapa banyak neuron yang akan diabaikan dalam satu *layer* selama pelatihan. Misalnya, jika *dropout rate* adalah 0.5, maka setengah dari jumlah neuron dalam *layer* akan diabaikan secara acak selama pelatihan [41].

6. *L2 Regularization*

Regularisasi L2, yang juga dikenal sebagai regularisasi Ridge, diterapkan dalam konteks model klasifikasi citra hiperspektral untuk mengatasi masalah *overfitting* dan meningkatkan generalisasi model. Metode ini melibatkan penambahan komponen regularisasi berupa jumlah nilai kuadrat dari parameter-parameter model ke dalam fungsi loss, menggunakan hyperparameter β untuk mengendalikan sejauh mana efek regularisasi L2 diterapkan. Rumus L2 Regularization menggambarkan bahwa setiap parameter model θ akan berkontribusi pada fungsi loss dengan jumlah nilai kuadrat dari bobotnya, dan semakin besar nilai β , semakin kuat efek regularisasi L2. Hasilnya, L2 Regularization cenderung mendorong bobot parameter untuk mendekati nol, tetapi tidak eksak, membantu mengendalikan

kompleksitas model dengan menghindari bobot yang terlalu besar. Dalam proses pelatihan, inialisasi model, forward propagation, perhitungan loss, penambahan regularisasi L2, dan optimisasi parameter-parameter model terjadi, dan akhirnya, L2 Regularizer membantu meningkatkan generalisasi dan relevansi fitur dalam klasifikasi citra hiperspektral, terutama dalam kasus data dengan dimensi tinggi [41].

2.8. Metode Evaluasi

Dalam mengevaluasi akurasi klasifikasi tutupan lahan, penting untuk memilih pengukuran akurasi yang tepat sehingga tujuan akurasi dapat disampaikan dengan jelas kepada pengguna akhir. *Confussion Matrix* adalah suatu teknik untuk memvisualisasikan performa algoritma klasifikasi. *Confussion Matrix* umumnya digunakan dalam berbagai penelitian klasifikasi tutupan lahan sebagai alat ukur akurasi tematik di bidang penginderaan jauh dan menjadi standar pengukuran *International Standard 19157*. *Confussion Matrix* direpresentasikan dalam bentuk Tabel dan membandingkan hasil klasifikasi tutupan lahan dengan referensi kebenaran dari *groundtruth* (peta kebenaran). Setiap kolom pada *Confussion Matrix* mewakili kelas kebenaran dasar, sedangkan nilai dalam kolom tersebut sesuai dengan pelabelan piksel kebenaran dasar pada citra tutupan lahan [44].

Pada klasifikasi tutupan lahan, *Confussion Matrix* biasanya diolah sebagai matriks evaluasi seperti *Overall Accuracy (OA)*, *Average Accuracy (AA)* dan *kappa coefficient* dan merupakan evaluasi matriks standar yang telah digunakan [45]. Mengacu pada penelitian-penelitian sebelumnya, dalam penelitian ini akan digunakan tiga metode evaluasi tersebut sebagai pengukur akurasi.

1. *Overall Accuracy (OA)*

Overall Accuracy adalah metrik evaluasi untuk mengukur seberapa akurat model klasifikasi dalam memprediksi kelas target pada seluruh data yang digunakan untuk evaluasi model tersebut. Secara sederhana, *Overall*

Accuracy menghitung persentase jumlah prediksi yang benar dibandingkan dengan total jumlah prediksi yang dilakukan [46]

$$\text{Overall Accuracy} = \frac{(\text{number of corretly classified pixels})}{(\text{total number of rest pixels})} \quad (2.6)$$

2. Average Accuracy (AA)

Average Accuracy atau akurasi rata-rata adalah metrik evaluasi performa model yang menghitung akurasi rata-rata dari setiap kelas pada data uji. *Average Accuracy* berguna untuk menghindari bias terhadap kelas mayoritas atau minoritas dalam dataset yang tidak seimbang [47]. *Average Accuray* (AA) merupakan nilai rata-rata dari setiap akurasi per kelas yang diprediksi secara benar dibagi jumlah total kelas yang ada.

$$\text{Accuracy} = \frac{\text{number of correctly classified pixels in the class}}{\text{total number of rest pixels in the class}} \quad (2.7)$$

$$\text{Average Accuracy} = \frac{\text{number of accuracy for each class}}{\text{number of class}} \quad (2.7)$$

3. Precision

Precision mengukur seberapa akurat model dalam mengidentifikasi sampel positif dari suatu kelas. Ini dihitung sebagai perbandingan antara jumlah sampel positif yang benar terklasifikasikan dengan total jumlah sampel yang diprediksi positif. *Precision* tinggi menunjukkan bahwa model cenderung memberikan sedikit *false positive*, yaitu sedikit sampel yang salah terklasifikasikan sebagai positif.

$$\text{Precision} = \frac{\text{True Positive classified pixels}}{\text{True Positive + False Positive Classified Pixels}} \quad (2.8)$$

4. Recall

Recall mengukur sejauh mana model dapat menemukan semua sampel positif dari suatu kelas. Ini dihitung sebagai perbandingan antara jumlah sampel positif yang benar terklasifikasikan dengan total jumlah sampel yang sebenarnya positif. *Recall* yang tinggi menunjukkan bahwa model memiliki kemampuan yang baik dalam mendeteksi sebanyak mungkin sampel positif yang ada.

$$Recall = \frac{True\ Positive\ classified\ pixels}{True\ Positive + False\ Negative\ Classified\ Pixels} \quad (2.9)$$

5. F-1 Score

F1-Score adalah *harmonic mean* antara *Precision* dan *Recall*. *F1-Score* digunakan untuk mengukur keseimbangan antara *Precision* dan *Recall*. *F1-Score* yang tinggi menunjukkan bahwa baik *Precision* maupun *Recall* memiliki nilai yang baik. *F1-Score* berguna saat ingin mempertimbangkan keduanya secara seimbang.

$$Average\ Accuracy = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (2.10)$$

6. Variabilitas Akurasi

Evaluasi variabilitas akurasi adalah proses untuk mengukur dan memahami sejauh mana akurasi model bervariasi atau fluktuasi selama pelatihan atau pengujian model. Ini merupakan langkah penting dalam evaluasi dan pemahaman kinerja model *machine learning*. Evaluasi variabilitas akurasi melibatkan analisis variasi hasil akurasi dari beberapa iterasi atau *epoch* yang berbeda dalam pelatihan atau pengujian model yang salah satunya ialah dengan mengukur standar deviasi dari iterasi yang dilakukan saat pelatihan. Standar deviasi merupakan sebuah indikator statistik yang berfungsi sebagai metrik pengukuran sebaran atau variasi data dari nilai rata-rata (*mean*). Dalam konteks pelatihan model *machine learning*, standar deviasi digunakan untuk mengevaluasi sejauh mana akurasi model bervariasi antar *epoch* selama proses pelatihan. Nilai standar deviasi yang lebih besar mencerminkan tingkat variasi yang lebih signifikan dalam akurasi model, sementara standar deviasi yang rendah menandakan tingkat konsistensi yang lebih tinggi, dengan akurasi yang mendekati nilai rata-rata secara stabil. Lebih lanjut, standar deviasi juga dapat dimanfaatkan untuk mendeteksi adanya anomali atau nilai yang secara signifikan berbeda dari norma. Dengan pemahaman yang mendalam mengenai standar deviasi, penelitian ini dapat mengambil keuntungan dari wawasan yang diperoleh

untuk pengambilan keputusan yang tepat terkait dengan pelatihan model, seperti menentukan titik berhenti pelatihan atau mengidentifikasi potensi *overfitting* pada model yang dikembangkan [41].

$$\sigma = \sqrt{\frac{\sum(X_i - \mu)^2}{N}} \quad (2.11)$$

Keterangan :

σ : standar deviasi.

N : jumlah total data

X_i : nilai data individual.

μ : nilai rata-rata (*mean*) dari data.

III. METODOLOGI PENELITIAN

3.1. Waktu dan Tempat Penelitian

Penelitian dilakukan di lingkungan jurusan Teknik Elektro Universitas Lampung dengan menggunakan personal laptop. Waktu penelitian berlangsung dari bulan Desember 2022 hingga Agustus 2023.

3.2. Alat dan Bahan

Beberapa alat dan bahan yang digunakan dalam penelitian ini yakni pada Tabel 3.1 dan 3.2.

Tabel 3.1 Alat

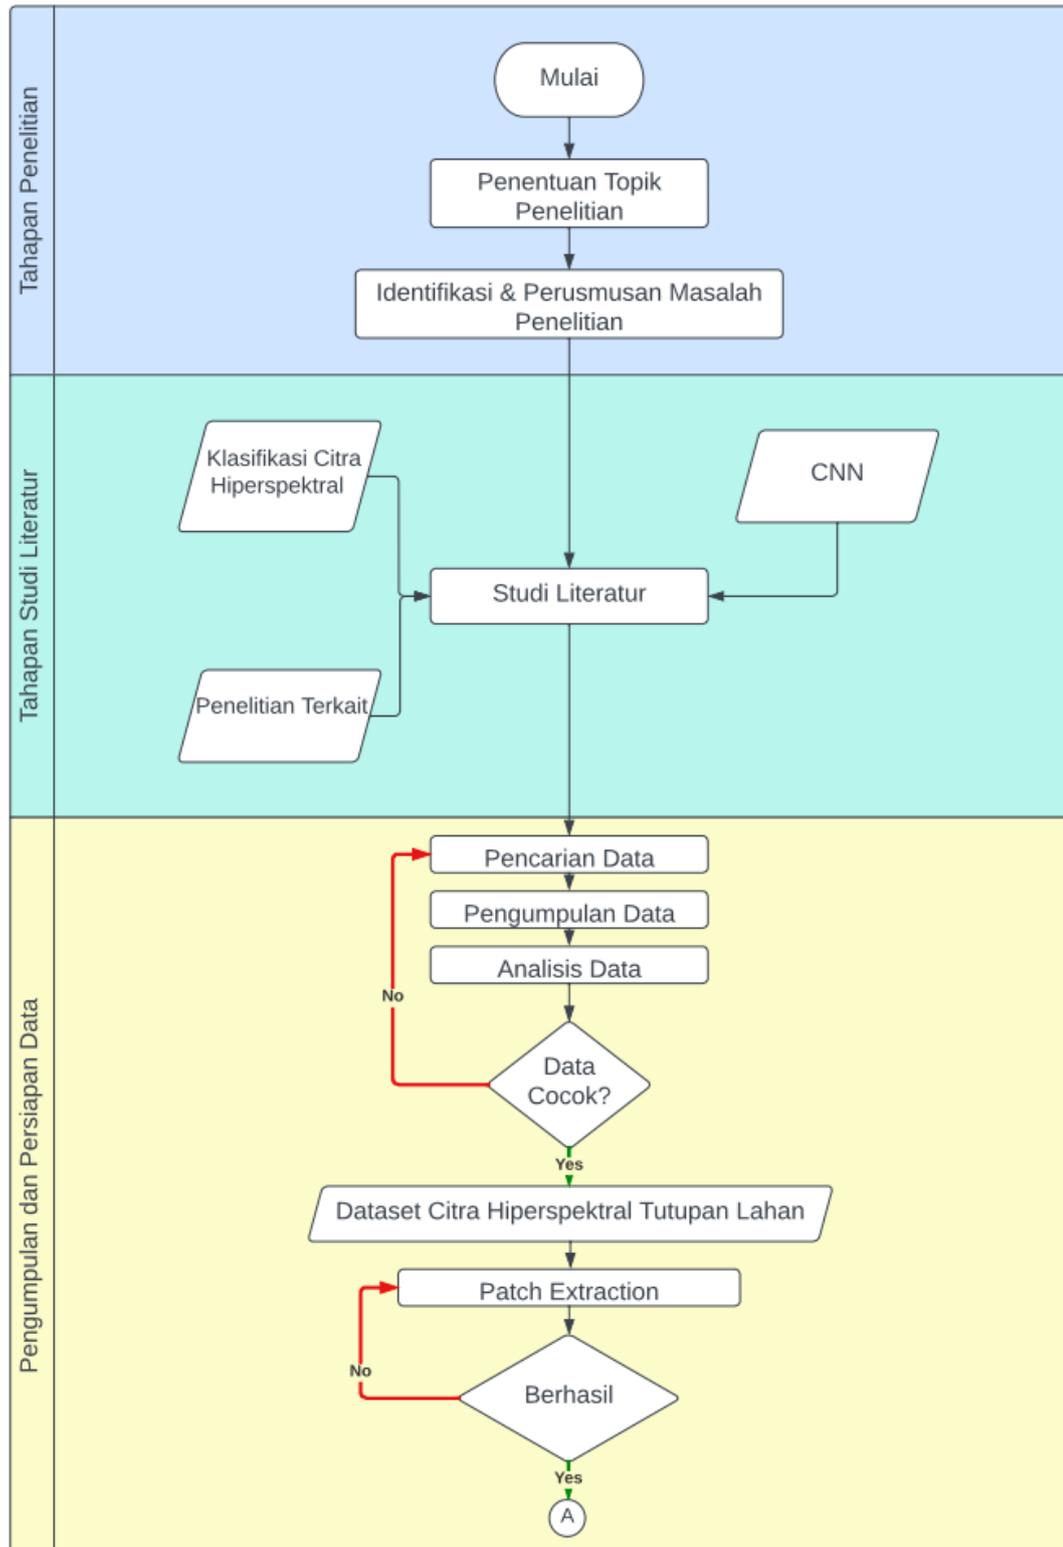
No	Alat	Keterangan
	Laptop	<i>Processor Intel(R) Core(TM) i7-8565U CPU @ 1.80GHz</i>
2	<i>Google Colab</i>	<i>Python Version 3.9.11</i>
3	<i>Python Library</i>	<i>Matplotlib</i>
		<i>Numpy</i>
		<i>Earthpy</i>
		<i>Plotly</i>
		<i>pandas</i>
		<i>Tensorflow, dan lainnya</i>

Tabel 3. 2. Bahan

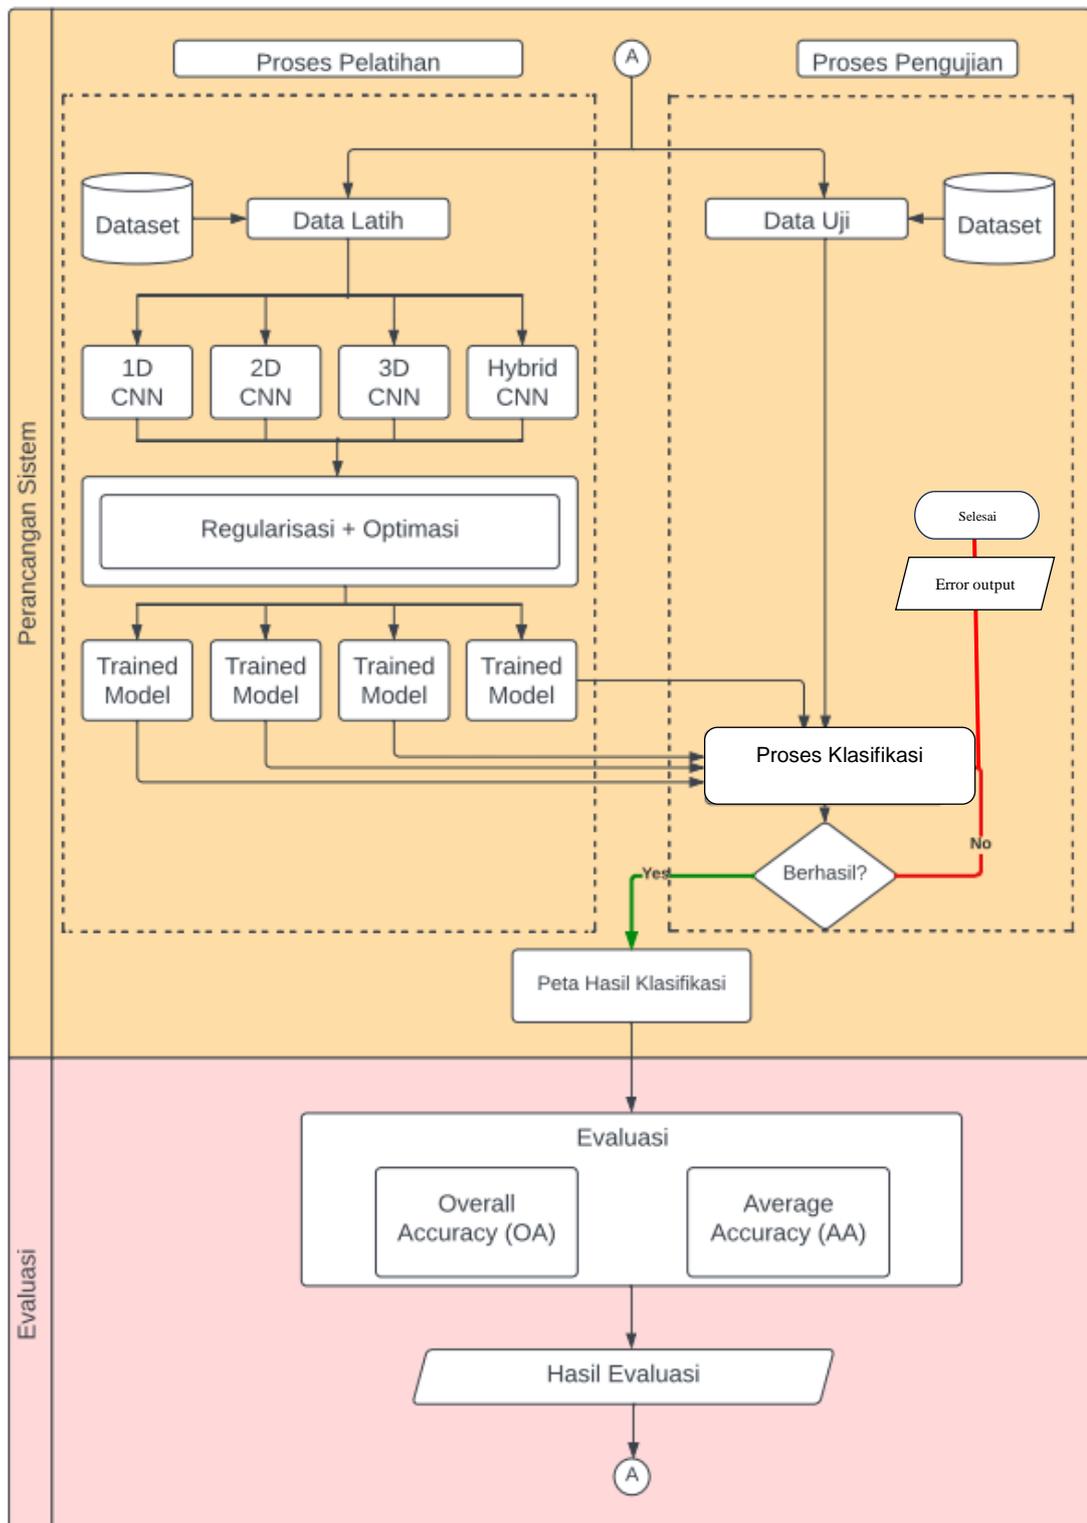
No	Bahan	Keterangan
1	<i>Pavia Centre Dataset</i>	<i>Spatial Resolution 1096 x 1096</i> <i>Jumlah Spectral Band 102</i>

3.3. Tahapan Penelitian

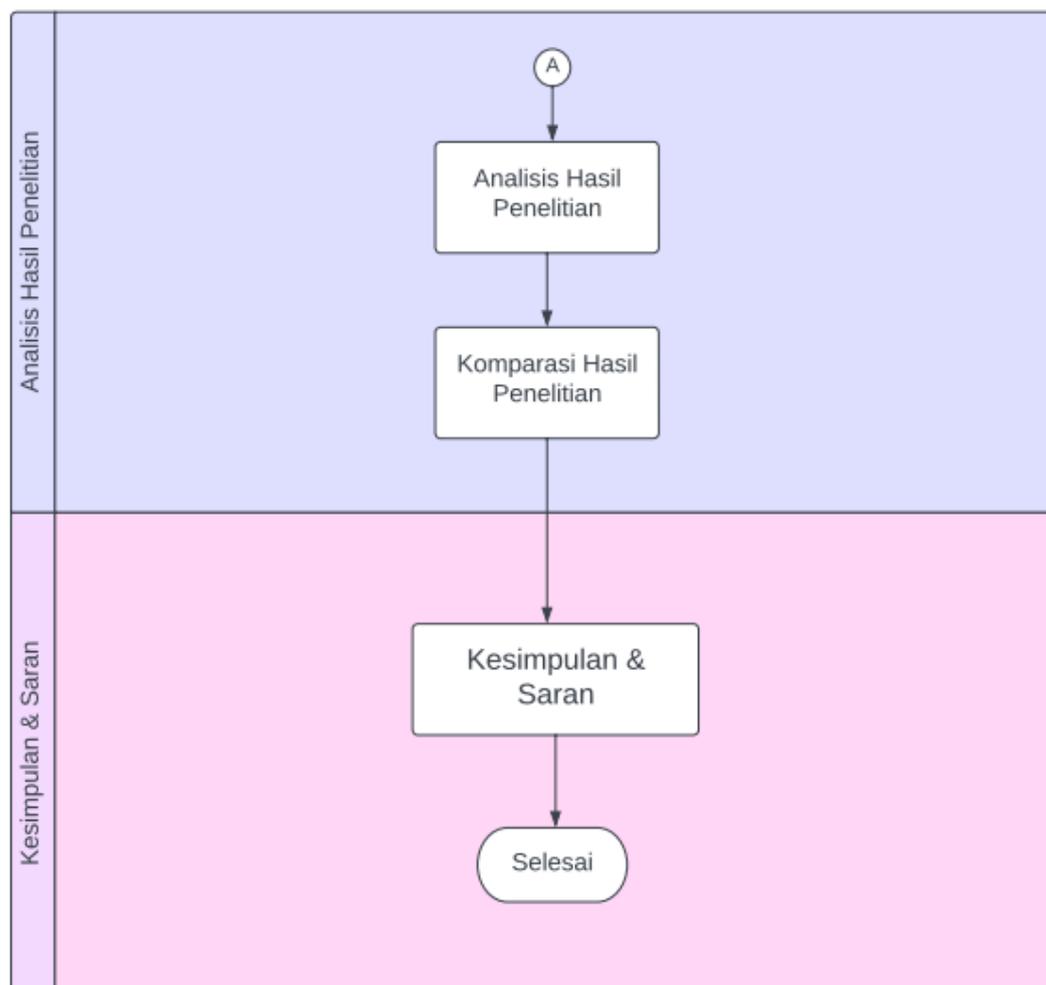
Konsep metodologi penelitian yang dilakukan secara keseluruhan mengacu pada metode *machine learning life cycle*. Metodologi penelitian yang digunakan dalam keseluruhan studi mengikuti konsep siklus *machine learning life cycle* yang terperinci dalam Gambar 3.1 Diagram Alir Penelitian. Siklus ini mencakup serangkaian tahapan, dimulai dari tahap penelitian awal, studi literatur, pengumpulan serta persiapan data, perancangan sistem klasifikasi, evaluasi model, analisis hasil penelitian, hingga penyusunan kesimpulan dan rekomendasi. Diagram ini berfungsi sebagai kerangka kerja yang memberikan panduan yang terperinci dan terstruktur bagi seluruh proses penelitian, memastikan konsistensi dan efisiensi dalam penerapan teknik *machine learning*, serta memastikan bahwa penelitian ini berjalan sesuai dengan kerangka kerja yang telah teruji dalam penelitian berbasis *machine learning*. Tahapan-tahapan yang telah disebutkan sebelumnya dijelaskan secara visual dalam Gambar 3.1 Diagram Alir Penelitian. Diagram alir penelitian adalah representasi grafis yang menggambarkan alur atau urutan langkah-langkah yang harus diikuti dalam suatu penelitian. Dalam konteks studi ini, diagram tersebut menggambarkan urutan langkah yang mencakup penelitian awal, studi literatur, pengumpulan serta persiapan data, perancangan sistem klasifikasi, evaluasi model, analisis hasil penelitian, hingga pembuatan kesimpulan dan rekomendasi. Alir penelitian ini berfungsi sebagai panduan visual yang membantu peneliti dan pembaca untuk memahami dengan rinci bagaimana penelitian ini dijalankan dan bagaimana setiap tahapan terkait satu sama lain, sehingga proses penelitian dapat berjalan dengan lebih efisien dan terstruktur. Tahapan-tahapan tersebut ditunjukkan pada gambar 3.1 Diagram Alir Penelitian.



Gambar 3.1 Diagram Alir Penelitian



Gambar 3.2 Diagram Alir Penelitian (lanjutan)



Gambar 3.3 Diagram Alir Penelitian (lanjutan)

3.4. Pengumpulan Data

Pengumpulan data adalah suatu proses yang digunakan untuk mendapatkan dan mengumpulkan data yang diperlukan. Adapun Langkah Langkah pengumpulan data pada penelitian ini adalah sebagai berikut:

1. Mencari sumber data dari *internet source* dan melalui studi literatur mengenai penelitian terkait.
2. Data yang didapatkan dari hasil pencarian dianalisis berdasarkan spesifikasi dan ketersediaan data.

3. Berdasarkan analisis data, didapatkan beberapa dataset tutupan lahan.
4. Melakukan perbandingan mengenai kesesuaian dataset dengan penelitian yang akan dilakukan sesuai dengan kebutuhan data.
5. Didapatkan dua dataset primer tutupan lahan berbasis citra hiperspektral yakni *Pavia Center*. Dataset ini dapat diakses pada situs publikasi resmi *Grupo de Inteligencia Computacional (GIC) (ehu.eus)*. Dataset berbasis citra hiperspektral ini diperoleh menggunakan sensor pesawat AVIRIS yang dikembangkan oleh NASA.

3.4.1. Analisis Data

Dataset yang digunakan adalah *Pavia Center* (PC). Pada masing masing citra telah dilakukan penghapusan *band spectral* (*band removal*) yang dinilai memiliki sensitivitas rendah. Tabel 3.4 menunjukkan spesifikasi dari dataset yang akan digunakan.

Tabel 3.3 Spesifikasi Dataset Yang Digunakan

No	Nama	Ukuran Gambar	Jumlah Band Spektral	Resolusi Spasial
1	<i>Pavia Center</i> (PC)	1096 × 1096	102	1,3

Pembagian kelas dari dataset PC ditunjukkan pada Tabel 3.4

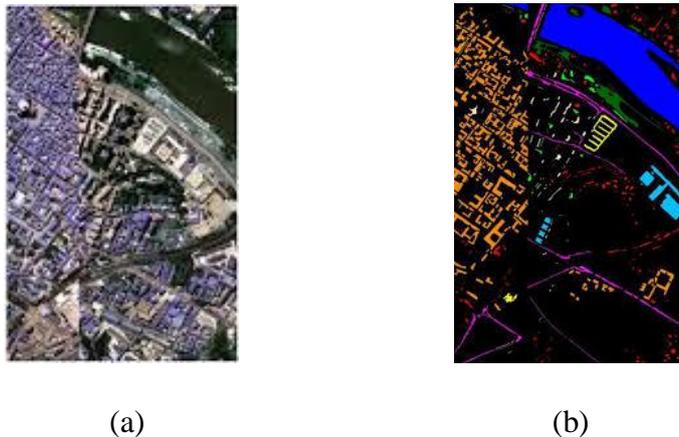
1. Dataset *Pavia Centre* (PC)

Kelas dataset *Pavia Center* (PC) Tabel 3.4, yang merupakan Tabel Kelas Dataset *Pavia Center* (PC), memberikan informasi yang sangat relevan mengenai komposisi dan karakteristik kelas dalam dataset *Pavia Center*. Dalam dataset ini, terdapat 9 kelas yang berbeda, dan masing-masing kelas memiliki jumlah sampel yang terperinci sebagaimana tercantum dalam tabel tersebut.

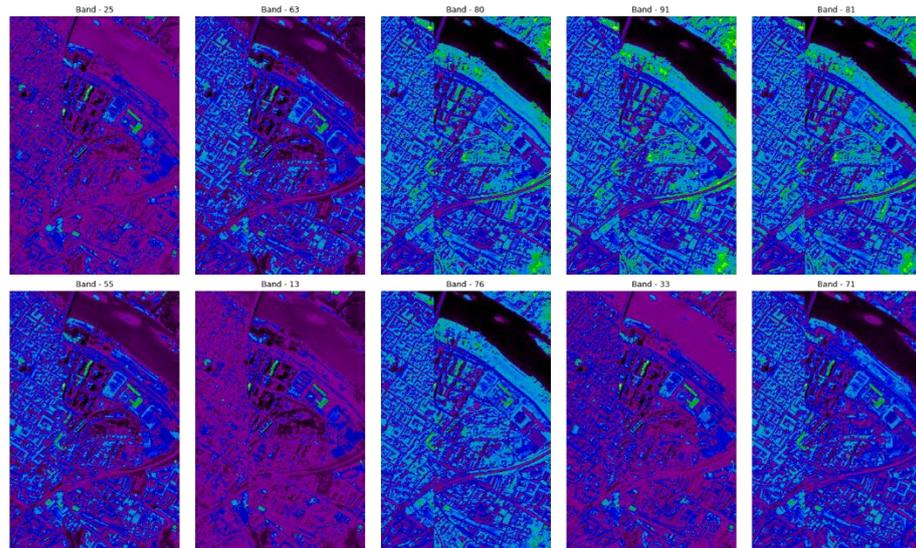
Tabel 3.4 Kelas Dataset *Pavia Centre* (PC)

No	Nama Kelas
1	<i>Water</i>
2	<i>Trees</i>
3	<i>Asphalt</i>
4	<i>Self-Blocking Bricks</i>
5	<i>Bitumen</i>
6	<i>Tiles</i>
7	<i>Shadows</i>
8	<i>Meadows</i>
9	<i>Bare Soil</i>

Gambar 3.2. menampilkan *false color* dan *groundtruth* (peta kebenaran) sebagai referensi dalam mengklasifikasikan kelas kelas data.

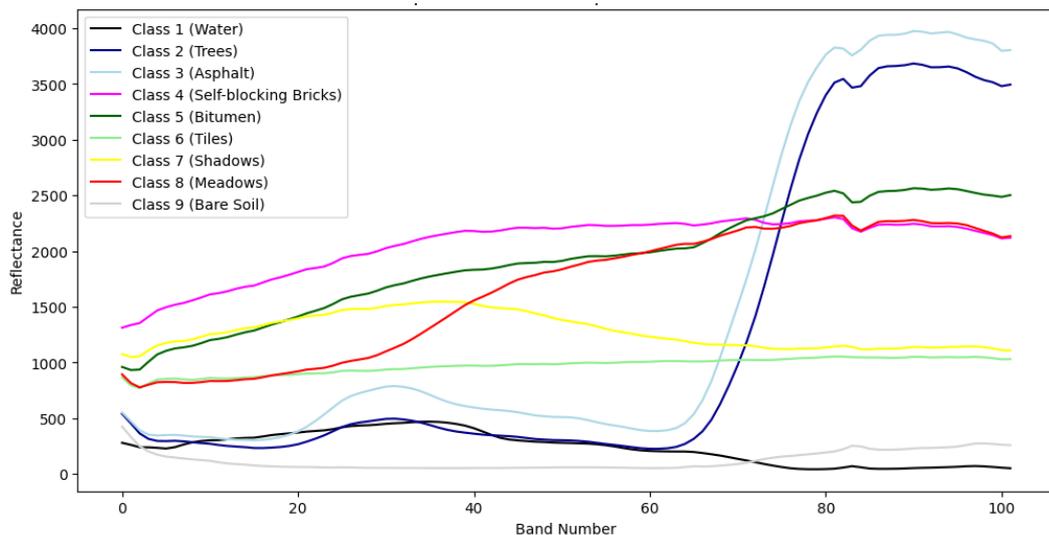
Gambar 3. 4. (a) *False Color*; (b) *Groundtruth* Dataset PC

Gambar 3.3 Visualisasi Data PC Dalam Beberapa Band Hiperspektral, menyajikan contoh visualisasi data hiperspektral dari dataset Pavia Center (PC) dalam sejumlah band secara acak. Visualisasi ini memberikan gambaran visual yang penting tentang sifat dan karakteristik data hiperspektral yang digunakan dalam penelitian ini. Dengan memeriksa berbagai band secara acak, peneliti dapat mengidentifikasi pola, fitur, dan variasi yang ada dalam data tersebut.



Gambar 3.3 Visualisasi Data PC Dalam Beberapa Band Hiperspektral

Berikut merupakan Spektrum Rata-rata yang ditampilkan oleh gambar 3.3 Rata-Rata *Reflectance Spectrum* Setiap Kelas Dataset *Pavia*.



Gambar 3.4 Rata-Rata *Reflectance Spectrum* Setiap Kelas Dataset *Pavia*

Dalam analisis citra hiperspektral, *mean spectrum reflectance* mengacu pada nilai rata-rata reflektansi dalam berbagai *band* spektral yang mencerminkan karakteristik spektral berbagai objek atau material dalam citra. Hal ini dilakukan dengan mengambil citra hiperspektral dari dataset *Pavia.mat*, yang memuat informasi reflektansi dalam banyak band spektral. Dalam konteks penelitian ini, tidak tersedia informasi panjang gelombang yang spesifik untuk setiap band, sehingga analisis

panjang gelombang yang tepat tidak dapat dilakukan serta satuan reflektansi yang digunakan dalam *output* kode adalah unit numerik yang merepresentasikan intensitas cahaya yang dipantulkan oleh material dalam citra hiperspektral. Hal ini karena tidak ada informasi yang diberikan oleh dataset yang mengindikasikan satuan reflektansi secara eksplisit, namun dalam citra hiperspektral, reflektansi sering diukur dalam satuan seperti *digital number* (DN) atau "*count*." Nilai-nilai ini mencerminkan intensitas cahaya yang terdeteksi oleh sensor hiperspektral dalam berbagai *band* spektral.

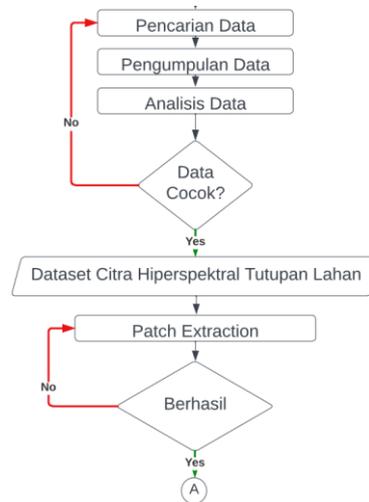
Pada Gambar 3.4 tersebut *Mean spectrum* menggambarkan rata-rata respons spektral atau tingkat reflektansi untuk setiap kelas dalam citra hiperspektral. Dalam contoh, perbedaan antara kelas 8 dan kelas 9 terlihat pada karakteristik spektral rata-rata keduanya. Kelas 8 memiliki reflektansi yang cenderung lebih tinggi (dari 1000 hingga 2000 *reflectance*) dibandingkan dengan kelas 9 yang memiliki reflektansi yang lebih rendah (dari 300 hingga 500 *reflectance*) dalam berbagai band spektral. Perbedaan ini mencerminkan sifat spektral yang berbeda antara kedua kelas, memungkinkan identifikasi jenis material atau objek yang ada dalam citra hiperspektral berdasarkan spektralnya.

Proses perhitungan *mean spectrum* dilakukan dengan mengelompokkan data berdasarkan kelas yang berbeda dalam citra, yang diidentifikasi oleh label kebenaran bumi atau *groundtruth* (*Pavia_gt.mat*). Rata-rata spektrum reflektansi dihitung untuk setiap kelas dengan mengambil nilai rata-rata reflektansi di setiap band spektral. Ini menciptakan spektrum rata-rata yang mencerminkan respons spektral rata-rata untuk material dalam kelas tersebut. Meskipun tidak ada informasi panjang gelombang spesifik, *mean spectrum* dapat dianggap sebagai untuk membedakan karakteristik spektral antara kelas berbeda dalam citra hiperspektral. Dalam konteks penelitian analisis citra hiperspektral dengan menggunakan dataset *Pavia Center* dikarenakan data yang digunakan juga sudah berbentuk data numerik spektral dalam format angka (*.mat*) maka tidak ada informasi panjang gelombang yang tersedia secara eksplisit untuk setiap band spektral dalam dataset ini. Kurangnya informasi panjang gelombang dapat menjadi hambatan ketika mencoba menentukan di mana setiap band berada dalam spektrum elektromagnetik, seperti kategori NIR, IR, atau MIR. Walaupun tidak ada informasi panjang gelombang

yang spesifik, analisis ini masih dapat memberikan wawasan yang berguna dalam mengidentifikasi material dan komponen dalam citra hiperspektral. Ini relevan dalam konteks penelitian ini yang hanya untuk mengklasifikasikan dan mengidentifikasi berbagai kelas objek berdasarkan respons spektral rata-ratanya.

3.4.2. Praproses Data

Tahapan pertama yang dilakukan sebelum melakukan pengujian adalah tahap praproses. Tahapan ini dilakukan untuk mempersiapkan data agar dapat digunakan dengan optimal. Dalam penelitian ini tahap praproses menggunakan *teknik sliding window*. Praproses data ditunjukkan pada gambar 3.3.

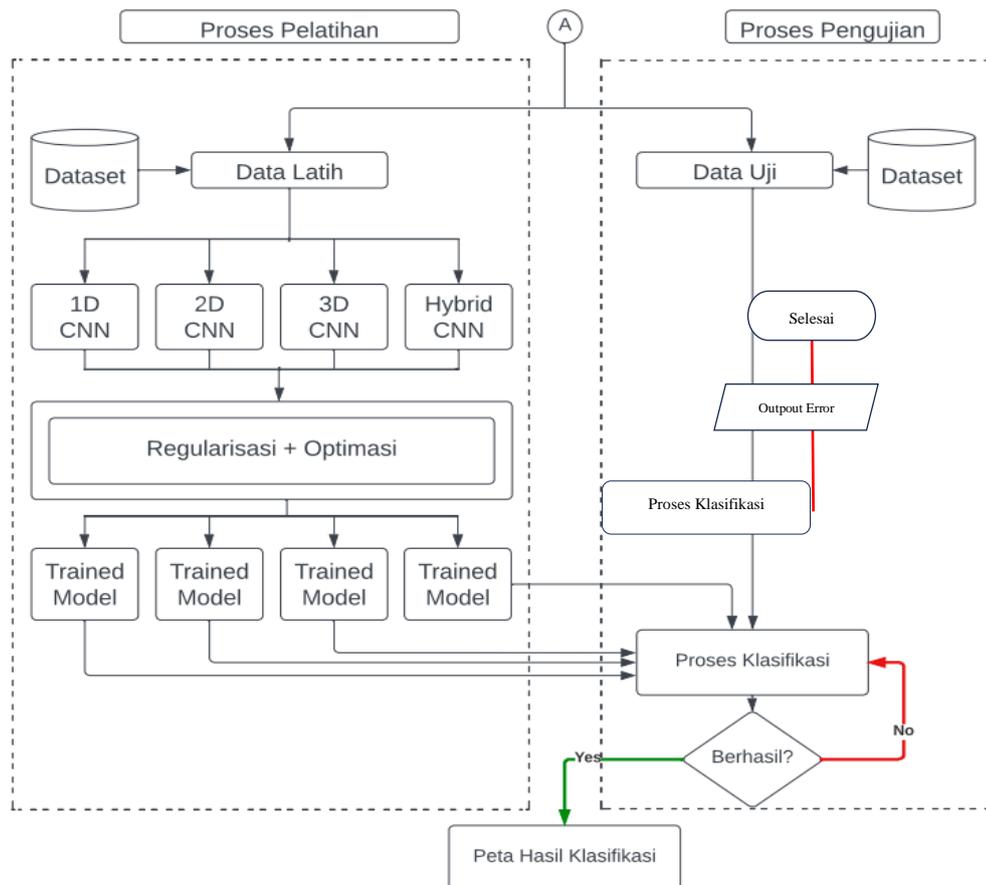


Gambar 3.5 Praproses Data

Dalam penelitian ini, salah satu teknik untuk mengekstraksi *patch* ialah sliding window. Teknik ini akan membagi gambar menjadi sejumlah kecil wilayah atau "jendela" yang berukuran sama, di mana setiap jendela mewakili sebuah citra kecil. Dengan cara ini, fitur-fitur dapat diambil dari setiap jendela secara terpisah dan digunakan sebagai *input* untuk algoritme klasifikasi atau deteksi objek.

3.5. Proses Klasifikasi

Pada tahap ini, informasi spektral dan spasial dari citra peta hiperspektral diekstraksi menggunakan model yang telah ditentukan. Akan dilakukan beberapa eksperimen pengujian dengan kombinasi metode *Regularized Hybrid CNN* dengan optimasi *Adaptive Moment Estimation* (Adam) dan CNN konvensional lainnya.



Gambar 3.6 Tahapan Klasifikasi

Tahapan pertama dari proses klasifikasi citra hiperspektral pada tutupan lahan ini adalah praproses. Pertama diimplementasikan teknik *over sampling* untuk menduplikat data dengan jumlah label rendah. Kedua citra akan direduksi dengan metode oversampling kemudian dilakukan augmentasi data untuk meningkatkan representasi fitur. Proses klasifikasi dilakukan dengan metode CNN standar 2D, CNN 3D dan *Regularized Hybrid CNN*. Hasil klasifikasi metode ini akan dievaluasi dengan beberapa metode evaluasi dan dibandingkan untuk menganalisis kinerja dari metode yang digunakan seperti yang ditunjukkan pada Gambar 3.5 Tahapan

Klasifikasi. Berikut merupakan tabel arsitektuk dari CNN yang digunakan pada penelitian ini ditunjukkan pada Tabel 3.5 Arsitektur CNN Konvensional dan Tabel 3.6 Arsitektur Regularized Hybrid CNN

Tabel 3.5 Arsitektur CNN Konvensional

<i>Layer</i>	<i>Layer Type</i>	<i>Output Shape</i>	<i>Param #</i>
1	<i>Layer1 (Conv1D)</i>	<i>(None, 102, 32)</i>	64
2	<i>Layer2 (Conv1D)</i>	<i>(None, 100, 64)</i>	6208
3	<i>MaxPooling_Layer1 (MaxPooling1D)</i>	<i>(None, 50, 64)</i>	0
4	<i>Dropout1 (Dropout)</i>	<i>(None, 50, 64)</i>	0
5	<i>Layer3 (Conv1D)</i>	<i>(None, 50, 64)</i>	4160
6	<i>Layer4 (Conv1D)</i>	<i>(None, 48, 128)</i>	24704
7	<i>MaxPooling_Layer2 (MaxPooling1D)</i>	<i>(None, 24, 128)</i>	0
8	<i>Dropout2 (Dropout)</i>	<i>(None, 64)</i>	0
9	<i>Flatten (Flatten)</i>	<i>(None, 3072)</i>	0
10	<i>DenseLayer1 (Dense)</i>	<i>(None, 200)</i>	614600
11	<i>DenseLayer1 (Dense)</i>	<i>(None, 50)</i>	10050
12	<i>OutputLayer (Dense)</i>	<i>(None, 10)</i>	510

Tabel 3.6 Arsitektur Regularized Hybrid CNN

<i>Layer</i>	<i>Layer Type</i>	<i>Output Shape</i>	<i>Param #</i>
1	<i>Input_1 (input_layer)</i>	<i>(None, 3, 3, 102, 1)</i>	0
2	<i>conv3d_3 (Conv3D)</i>	<i>(None, 3, 3, 102, 16)</i>	128
3	<i>conv3d_4 (Conv3D)</i>	<i>(None, 3, 3, 102, 32)</i>	23072
4	<i>conv3d_5 (Conv3D)</i>	<i>(None, 3, 3, 102, 32)</i>	179232
5	<i>reshape (Reshape)</i>	<i>(None, 3, 3, 3264)</i>	0
6	<i>conv2d (Conv2D)</i>	<i>(None, 3, 3, 64)</i>	1880128
7	<i>conv2d_1 (Conv2D)</i>	<i>(None, 3, 3, 64)</i>	26928
8	<i>global_average_pooling2d (GlobalAveragePooling2D)</i>	<i>(None, 64)</i>	0
9	<i>flatten_1 (Flatten)</i>	<i>(None, 64)</i>	0
10	<i>dense_2 (Dense)</i>	<i>(None, 50)</i>	3250
11	<i>Dropout_1 (Dropout)</i>	<i>(None, 50)</i>	0
12	<i>dense_3 (Dense)</i>	<i>(None, 20)</i>	1020
13	<i>Dropout_2 (Dropout)</i>	<i>(None, 20)</i>	0
14	<i>dense_4 (Dense)</i>	<i>(None, 9)</i>	189

Percobaan kombinasi metode ditampilkan pada Tabel 3.8 yang pada percobaan kombinasi metode ini menghasilkan 14 model dengan metode yang berbeda, yakni menggunakan 2 optimasi SGD dan ADAM serta percobaan dengan 1D, 2D, 3D dan Hybrid CNN dan dengan percobaan menggunakan regularisasi dan tidak menggunakan regularisasi. Terkhusus untuk metode 1D CNN tidak melakukan percobaan dengan menggunakan regularisasi hal ini dikarenakan model 1D CNN terlalu sederhana untuk menggunakan metode regularisasi L2 *regularization*.

Tabel 3.7 Percobaan Kombinasi Metode

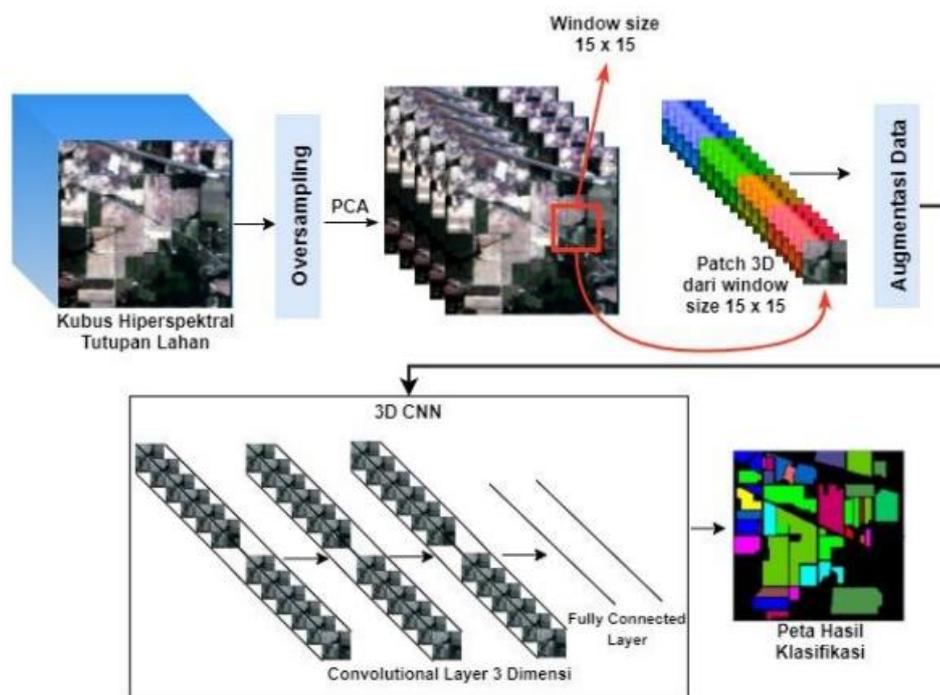
Model	Metode	Optimizer
1	1D CNN	SGD
2	1D CNN	Adam
3	2D CNN	SGD
4	2D CNN	Adam
5	Regularisasi + 2D CNN	SGD
6	Regularisasi + 2D CNN	Adam
7	3D CNN	SGD
8	3D CNN	Adam
9	Regularisasi + 3D CNN	SGD
10	Regularisasi + 3D CNN	Adam
11	<i>Hybrid CNN</i>	SGD
12	<i>Hybrid CNN</i>	Adam
13	Regularisasi + <i>Hybrid CNN</i>	SGD
14	Regularisasi + <i>Hybrid CNN</i>	Adam

Pada percobaan ini menggunakan perbandingan dengan dua optimasi yang berbeda yakni SGD dan Adam, mengacu pada tinjauan pustaka bahwasannya kedua optimasi ini memiliki karakteristik yang sesuai untuk klasifikasi dengan metode CNN. Percobaan kombinasi metode ini juga akan membandingkan penggunaan regularisasi dan non-regularisasi hal ini untuk membuktikan apakah regularisasi akan meningkatkan akurasi model. Pada penelitian ini Model 1 dan 2 dengan metode 1D CNN tidak dilakukan percobaan dengan teknik regularisasi, hal ini dikarenakan

metode yang digunakan tidak *compatible* untuk menggunakan teknik regularisasi didalamnya sehingga untuk metode 1D CNN hanya melakukan perbandingan optimasinya saja.

3.6. Ekstraksi Fitur dan Klasifikasi

Proses klasifikasi pada penelitian ini melingkupi pengolahan data dengan melakukan beberapa tahap praproses seperti yang telah dijabarkan pada poin 3.1, tahap selanjutnya adalah ekstraksi fitur oleh *layer-layer* yang telah ditentukan. Pada tahap akhir data yang telah diekstrak tersebut diklasifikasi dengan *fully connected layer*. Detail proses klasifikasi citra hiperspektral dengan metode 3D CNN ini dapat dilihat pada Gambar 3.7.



Gambar 3.6 Ilustrasi Klasifikasi Citra Hiperspektral Tutupan Lahan

Pada Gambar 3.6 kubus citra hiperspektral dengan ukuran 145x145 piksel melalui tahap praproses yakni *patch extraction*. *Window size* yang dipilih turut mempengaruhi penggunaan perangkat, dimana semakin besar *window size* maka alokasi memori juga ikut meningkat. Sebagai bentuk efisiensi model dan

kompleksitas seperti yang dijabarkan pada bab 1, maka pada penelitian ini penulis menggunakan *window size* berukuran 5 x 5. Proses ekstraksi fitur menerima *input* dari data yang telah melalui tahap praproses dan pemotongan citra. Gabungan dua konvolusi yang berbeda ini digunakan untuk memperoleh informasi spektral dan spasial secara bersamaan dengan komputasi yang rendah. Pada model ini *patch* data tiga dimensi dari *window size* 5 x 5 diinput ke *layer* Conv3D pada 3D CNN sehingga diperoleh dua fitur spektral spasial dari citra hiperspektral. Sedangkan operasi Conv2D setelahnya dapat menurunkan kompleksitas jika dibandingkan dengan model 3D CNN saja. Gambar 3.6 menunjukkan ilustrasi proses klasifikasi citra hiperspektral tutupan lahan pada penelitian ini. Berikut merupakan baris source code yang digunakan untuk model klasifikasi dengan menggunakan *regularized hybrid cnn* dengan *adam optimization* yang diusulkan.

```
import matplotlib.pyplot as plt
import numpy as np
import earthpy.plot as ep
import seaborn as sns
import earthpy.spatial as es
import plotly.graph_objects as go
import plotly.express as px
from scipy.io import loadmat
import pandas as pd
from sklearn.preprocessing import minmax_scale
from sklearn.model_selection import train_test_split
from sklearn.metrics import (accuracy_score,
                             Confusion_matrix, classification_report)
import tensorflow as tf
from tensorflow import keras
from keras import Input, Model
from tensorflow.keras.layers import Input, Dense, MaxPooling2D, MaxPooling3D,
Dropout, Flatten, Conv2D, Conv3D, LeakyReLU, GlobalAveragePooling2D, Reshape
from tensorflow.keras.models import Sequential
from tensorflow.keras.utils import to_categorical
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint, TensorBoard
from tqdm import tqdm
from numpy.random import seed
from time import time
seed(11)
```

Gambar 3.7 Source Code Library

3.7. Evaluasi

Pada tahap ini dilakukan evaluasi untuk mengukur kinerja dari algoritma yang telah diimplementasikan pada dataset tutupan lahan. Untuk perbandingan kinerja algoritma tersebut, digunakan tiga metode evaluasi yaitu *Overall Accuracy (OA)*, *Average Accuracy (AA)* dan Uji Variabilitas dengan standar deviasi yang memproses hasil klasifikasi dengan melakukan perhitungan data dari *Confussion Matrix*. Contoh *Confussion Matrix* terdapat pada gambar 3.8 dibawah ini. Sebagai contoh berikut diasjikan perhitungan evaluasi pada hasil klasifikasi model 14 *Regularized Hybrid CNN*.



Gambar 3.8 *Confussion Matrix*

1. *Overall Accuracy*

$$\text{Overall Accuracy} = \frac{(\text{number of corretly classified pixels})}{(\text{total number of rest pixels})} \quad (2.12)$$

Jumlah piksel yang diklasifikasi dengan benar :

$$19792 + 2150 + 918 + 775 + 1962 + 2741 + 2074 + 12840 + 859 = 44111$$

Total Piksel yang diujikan :

$$19792 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 2150 + 7 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 129 + 918 + 0 + 1 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 775 + 10 + 7 + 4 + 0 + 0 + 0 + 0 + 2 + 26 + 1962 + 5 + 15 + 2 + 0 + 0 + 0 + 0 + 0 + 2 + 1 + 2741$$

$$+ 92 + 6 + 0 + 0 + 0 + 0 + 3 + 1 + 19 + 2074 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 2 + 1 + 12840 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 859 = 44427$$

$$\text{Overall Accuracy} = \frac{44111}{44427} = 0,992 \times 100 = 99,2 \%$$

2. Average Accuracy

$$\text{Average Accuracy} = \frac{\text{number of accuracy for each class}}{\text{number of class}} \quad (2.13)$$

Jumlah piksel yang berhasil diklasifikasi dibagi total piksel :

$$\text{Akurasi Kelas 1} = 19792 / (19792 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0) = 1.0$$

(100%)

$$\text{Akurasi Kelas 2} = 2150 / (0 + 2150 + 7 + 0 + 0 + 0 + 0 + 0 + 0) = 0,996$$

(sekitar 99,68%)

$$\text{Akurasi Kelas 3} = 918 / (0 + 129 + 918 + 0 + 1 + 0 + 0 + 0 + 0) = 0,871$$

(sekitar 87,17%)

$$\text{Akurasi Kelas 4} = 775 / (0 + 0 + 0 + 775 + 10 + 7 + 4 + 0 + 0) = 0,971$$

(sekitar 97,11%)

$$\text{Akurasi Kelas 5} = 1962 / (0 + 0 + 2 + 26 + 1962 + 5 + 15 + 2 + 0) = 0,972$$

(sekitar 97,23%)

$$\text{Akurasi Kelas 6} = 2741 / (0 + 0 + 0 + 2 + 1 + 2741 + 92 + 6 + 0) = 0,966$$

(sekitar 96,63%)

$$\text{Akurasi Kelas 7} = 2074 / (0 + 0 + 0 + 3 + 1 + 19 + 2074 + 0 + 0) = 0,989$$

(sekitar 98,94%)

$$\text{Akurasi Kelas 8} = 12840 / (0 + 0 + 0 + 0 + 0 + 2 + 1 + 12840 + 0) = 0,999$$

(sekitar 99,92%)

$$\text{Akurasi Kelas 9} = 859 / (0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 859) = 1,0 \text{ (100\%)}$$

$$\text{Average Accuracy} = (1,0 + 0,996 + 0,871 + 0,971 + 0,972 + 0,966 + 0,989 + 0,999 + 1,0) / 9 = 0,974 \times 100 = 97,4 \%$$

3. Standar Deviasi

Pada uji variabilitas model 14 ini menggunakan 30 kali iterasi (*epochs*), berikut merupakan perhitungannya :

$$\sigma = \sqrt{\frac{\sum(Xi-\mu)^2}{N}} \quad (2.17)$$

$$\begin{aligned} \sum(Xi - \mu)^2 &= (0,9771 - 0,9756)^2 + (0,9775 - 0,9756)^2 + (0,9796 - 0,9756)^2 \\ &+ (0,9792 - 0,9756)^2 + (0,9793 - 0,9756)^2 + (0,9787 - 0,9756)^2 + \\ &(0,9799 - 0,9756)^2 + (0,9779 - 0,9756)^2 + (0,9786 - 0,9756)^2 + (0,9802 \\ &- 0,9756)^2 + (0,9818 - 0,9756)^2 + (0,9795 - 0,9756)^2 + (0,9773 - 0,9756) \\ &^2 + (0,9815 - 0,9756)^2 + (0,9813 - 0,9756)^2 + (0,9811 - 0,9756)^2 + (0,9828 \\ &- 0,9756)^2 + (0,9826 - 0,9756)^2 + (0,9830 - 0,9756)^2 + (0,9820 - 0,9756) \\ &^2 + (0,9848 - 0,756)^2 + (0,9816 - 0,9756)^2 + (0,9839 - 0,9756)^2 + (0,9840 \\ &- 0,9756)^2 + (0,9013 - 0,9756)^2 + (0,9539 - 0,9756)^2 + (0,9647 - 0,9756) \\ &^2 + (0,9642 - 0,9756)^2 + (0,9736 - 0,9756)^2 + (0,9751 - 0,9756)^2 \end{aligned}$$

$$\sum(Xi - \mu)^2 = 0,0069672$$

$$N = 30$$

$$\sigma = \sqrt{\frac{0,0069672}{30}} = 0,0152$$

3.8. Analisis Hasil Penelitian

Pada tahap ini akan dilakukan proses pengujian dengan beberapa eksperimen dengan kombinasi model yang digunakan. Hasil pengujian berupa akan ditampilkan dalam bentuk Tabel yang berisi nilai-nilai akurasi, gambar dan grafik.

3.9. Komparasi Hasil Penelitian

Pada tahap ini dilakukan komparasi dari 14 model yang telah diuji sebelumnya. Hasil komparasi ini akan digunakan sebagai acuan untuk menentukan model

dengan akurasi klasifikasi terbaik dan juga membandingkan dengan performa hasil akurasi penelitian terdahulu serta melakukan perbandingan dengan *benchmark* (acuan) data *ground truth pavia center*

3.10. Kesimpulan Dan Saran

Pada bagian ini menyajikan hasil ringkasan dari hasil uji coba yang telah dilakukan serta memberikan saran untuk penelitian selanjutnya.

V. KESIMPULAN DAN SARAN

Penelitian ini dilakukan dengan mengkombinasikan metode *Hybrid Convolutional Neural Network* dengan teknik regularisasi dan dengan dua metode percobaan optimasi yaitu Adam dan SGD sehingga menghasilkan 14 kombinasi model. Model-model ini diuji pada dataset *hyperspectral Pavia Center* yang memiliki jenis dan karakteristik lahan sesuai dengan aturan LCCS (*Land Cover Classification System*). Pada bab ini akan disampaikan kesimpulan dan saran dari hasil perbandingan dan analisisnya.

5.1. Kesimpulan

Berikut merupakan kesimpulan yang dapat ditarik berdasarkan penelitian yang telah dilakukan :

1. Penelitian ini berhasil mengembangkan metode konvensional CNN dengan Akurasi tertinggi pada dataset *Pavia* yakni dengan AA sebesar 97.50% dan OA sebesar 99.25% terdapat pada model 14 yakni dengan metode Hybrid CNN dan teknik regularisasi dengan optimasi Adam
2. Kombinasi teknik Regularisasi dengan optimasi adam pada dataset *pavia center* terbukti dapat meningkatkan akurasi dan performa klasifikasi, hal ini dibuktikan berdasarkan perbandingan model bahwa teknik regularisasi dan optimasi adam memiliki keakuratan yang lebih unggul 0.50-1%
3. Penggunaan optimasi adam dan teknik regularisasi pada dataset *pavia center* dapat mengatasi masalah pada klasifikasi, hal ini dibuktikan dengan waktu yang lebih efisien dan hasil akurasi yang unggul dengan waktu komputasi sebesar 5.68 menit mendapatkan akurasi keseluruhan sebesar 99.25%

5.2. Saran

Adapun saran untuk penelitian selanjutnya antara lain :

1. Hasil penelitian yang telah dilakukan dapat dikembangkan kembali dengan melakukan eksperimen menggunakan metode dan teknik teknik klasifikasi lainnya.
2. Penelitian selanjutnya dapat membandingkan dengan menggunakan dataset yang lebih bervariasi yang memiliki karakteristik berbeda untuk memvalidasi sekaligus pembandingan kemampuan model yang dikembangkan
3. Penelitian selanjutnya diharapkan dapat menggunakan objek *hyperspectral* yang didapatkan secara langsung untuk keperluan studi kasus suatu lahan tertentu (*real time study case*).

DAFTAR PUSTAKA

- [1] D. Kosasih, M. Saleh Buce and L. Budi Prasetyo, "Visual and Digital Interpretations for Land Cover Classification in Kuningan District, West Java," *Jurnal Ilmu Pertanian Indonesia*, vol. 24, no. 2, pp. 101-108, 2019.
- [2] Y. Li, G. Yang, Z. Xu, W. Chen and L. Zhou, "Multi-Temporal Classification of Land Cover Using Sentinel-2 data with Integrated Prior Knowledge," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 178, pp. 102-115, 2021.
- [3] Zhe Yuan, Jijun Xu, Yongqiang Wang and Bo Yan " Analyzing the influence of land use/land cover change on landscape pattern and ecosystem services in the Poyang Lake Region, China.," *Journal of Environmental Science and Pollution Research*, vol. 28, pp 27193-27206, 2022.
- [4] R. Kokaly, G. Asner, S. Ollinger, M. Martin and C. Wessman, "Characterizing Canopy Biochemistry From Imaging Spectroscopy And its Application to Ecosystem Studies," *Remote Sensing of Environment*, vol. 219, pp. 72-89, 2018.
- [5] W. LI, G. Wu, S. Member and F. Zhang, "Hyperspectral Image Classification Using Deep Pixel-Pair Features," *Journal of Sensors*, vol. 55, no. 22, pp. 844-853, 2017.
- [6] Wie Li, Chen Chen, Hongjun Su and D. Qian, "Local Binary Patterns and Extreme Learning Machine for Hyperspectral Imagery Classification," *IEEE Trans Geoscience Remote Sensing*, vol 53, no 7, pp. 8681-3693, 2015.
- [7] W. Tianyi, Z. Zhe, Chengxiang Qiu and J. Xiuping , "Adaptable Convolutional Network for Hyperspectral Image Classification," *Journal of Remote Sensing*, vol. 13, no. 18, pp. 3637, 2021.
- [8] Bin Xie, Hankui K. Zhang and Jie Xue, " Deep Convolutional Neural Network for Mapping Smallholder Agriculture Using High Spatial Resolution Satellite Image," *Journal of Sensors*, vol 19, no 10, pp. 2398, 2019.
- [9] Yangyu.Huang, Fan Zhang, Wi Hu andYangyu Huang "A deep convolutional neural network for hyperspectral image classification," *Journal of Sensors*, vol 2015 pp. 1-12, 2015.

- [10] Hong Huang, Chunyu Pu, Yuan Li and Yule Duan "Adaptive Residual Convolutional Neural Network for Hyperspectral Image Classification," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol 13, pp. 2520-2531, 2020.
- [11] Y. Feng, X. Wu, H. Chen and Y. Chen, "1D convolutional neural networks for hyperspectral image classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, no. 10, pp. 7606-7618, 2019.
- [12] Y. Chen , Z. Li, H. Sun, M. Lin and B. Luo, "hyperspectral image classification method based on stacked 2D convolutional neural networks," *Remote Sensing*, vol. 10, no. 12, p. 1986, 2018.
- [13] J. Ma, H. Li, X. Liu and C. Chen, "A 3D convolutional neural network with new feature fusion strategy for hyperspectral image classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 58, no. 5, pp. 3199-3213, 2020.
- [14] G. Saeed, A. Dariush, S. Alireza, Z. Na and T. Aqil, "Hyperspectral Image Classification Using a Hybrid 3D-2D Convolutional Neural Networks," *IEEE Journal Of Selected Topics In Applied Earth Observations and Remote Sensing*, vol 14, pp 7570-7588 2021.
- [15] M. Ahmad, M. Mazzara and S. Distefano, "3D/2D regularized CNN feature hierarchy for Hyperspectral image classification," *ARXIV Preprint*, 2021. <https://doi.org/10.48550/arXiv.2104.12136>.
- [16] W. Samek, Binder A, G. Montavon , S. Lapuchskin and K. Muller, "Evaluating the visualization of what a deep neural network has learned," *IEEE transactions on neural networks and learning systems*, vol 28, no. 11 pp. 2660-2673, 2017.
- [17] E. D. Science, "Overfitting in *Machine learning*: What It Is and How to Prevent It," Elite Data Science, 6 july 2022. [Online]. Available: <https://elitedatascience.com/overfitting-in-machine-learning>. [Accessed 30 September 2023].
- [18] H. Yang, S. Li, J. Chen, X. Zhang and S. Xu, "The Standardization and harmonization of land cover classification systems towards harmonized dataset : A review," *ISPRS International Journal of Geo-Information*, vol. 6, no. 5, pp. 1-16, 2017.

- [19] BSN, "Badan Standarisasi Nasional Klasifikasi Penutup Lahan," 2010. [Online]. Available: <https://sispk.bsn.go.id>.
- [20] J. Campbell, Introduction to remote sensing, CRC Press, 2015.
- [21] C. Dushyant D, D. Ketan D, A. Timur R and P. Nirav K, "Transforming Fruit Farming in a hi-tech Way through Remote Sensing: A Review," *Biological Forum*, vol. 15, no. 2, pp. 333-341, 2023.
- [22] P. Choudury and S. Rana, Fundamentals of Remote Sensing and Airphoto Interpretation, Taylor & Francis, 2017.
- [23] NASA, "NASA Tour of the EM Spectrum," NASA, [Online]. Available: <http://missionscience.nasa.gov/ems/index.html>. [Accessed April 2023].
- [24] J. Zhang, L. Gao, L. Zhang, X. Zhao and J. Li, "Hyperspectral Image Classification Based on Multiscale Hybrid Networks and Attention Mechanisms," *Journal of Remote Sensing*, vol 15, no. 11, pp. 2720, 2023.
- [25] X. Chen, C. Yan, Z. Zhang, Y. Zhou, J. Chen and L. Chen, "Hyperspectral Remote Sensing for Mangrove Leaf Nitrogen Concentration: Model Development and Comparison," *Remote Sensing*, vol. 11, no. 4, p. 462, 2019.
- [26] Z. Wang, B. Du, L. Zhang and X. Jia, "A Novel Semisupervised Active-Learning Algorithm for Hyperspectral Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 6, pp. 3071-3083, 2017.
- [27] E. Bedini, "The use of hyperspectral remote sensing for mineral exploration: a review," *Journal of hyperspectral remote sensing*, vol 7, no. 4, pp. 189-211, 2017.
- [28] J. Zabala, "Feature Extraction and Data reduction for hyperspectral remote sensing earth observation" Ph.D. dissertation, Univ of Strathclyde, Jun 2015.
- [29] A. Gregorio Di, L. Jansen and C. de Bie, "Land Cover Classification System: Classification Concepts and User Manual," *Food and Agriculture Organization of the United Nations (FAO)*, 2011.
- [30] X. Yang, C. Lo and X. Li, "A planar kernel-based method for classification of multisource remote sensing data," *IEEE Transactions on geoscience and remote sensing*, vol. 41, no. 9, pp. 2016-2024, 2003.

- [31] G. M Foody, "Status of land cover classification accuracy assesment," *journal of remote sensing of Environtment*, vol. 80, no. 1, pp. 185-201, 2002.
- [32] Y. LeCun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based learning applied to document recognition," in *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998.
- [33] I. Goodfellow, Y. Bengio and A. Courville, "Deep Learning," in *Deep Learning*, Cambridge, Massachusetts, USA, MIT Press, 2016, pp. 331-353.
- [34] N. S. Kwak, "A convolutional neural network for steady state visual evoked potential classification under ambulatory environment," *Journal of PLoS ONE*, vol. 12, no. 2, 2017.
- [35] Y. Zhang, "Understanding Convolutional Neural Networks with A Mathematical Model," *Journal of Physics: Conference Series*, vol. 1168, no. 4, 2019.
- [36] Y. LeCun, Y. Bengio and G. Hinton, "Deep learning," *Journal of Nature*, vol. 521, no. 7553, pp. 436-444, 2015.
- [37] X. Yang, L. Feng and L. Sun, "Hyperspectral image classification with deep learning models," *Journal of Remote Sensing*, vol. 10, no. 8, p. 1333, 2018.
- [38] O'Shea and R. Nash, "An introduction to Convolutional Neural Network," *arXiv Preprint*, November 2015.
- [39] L. Ying, Z. Haokui and S. Qiang, "Spectral–Spatial Classification of Hyperspectral Imagery with 3D Convolutional Neural Network," *remote sensing*, vol. 9, no. 67, 2017.
- [40] X. Ma, Y. Zhang, Z. Wang and Y. Liu, "Improved Leaky ReLU Activated Convolutional Neural Network for Hyperspectral Image Classification," *Remote Sensing*, vol. 10, no. 3, pp. 1-15, 2018.
- [41] I. Daqiqi, *Machine learning*, Riau: UNRI Press, 2021.
- [42] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," *Journal of machine learningresearch*, vol. 15, no. 1, pp. 1929-1958, 2014.
- [43] A. B, "Multiple Instance Fuzzy Inference Neural Network," *arXiv Preprint*, October 2016.

- [44] F. Ariza-Lopes, J. Rodriguez-Avi and M. Alba-Ferandez, "Complete control of an observed *Confussion Matrix*," *International Geoscience and Remote Sensing Symposium (IGARSS)*, pp. 1222-1225, july 2018.
- [45] P. Sarmiento, "Error and Uncertainty in the accuract assesment of land cover maps," Ph.D. dissertation, *NOVA Information Management School*, pp. 1-139, 2015.
- [46] M. Hossin and M. Sulaiman, "A review on evaluation metrics for data classification evaluations," *Journal of emerging technologies in web intelligence*, vol. 7, no. 2, pp. 97-106, 2015.
- [47] R. Kotsiantis, "Supervised Machine learning: A Review of Classification Techniques. Informatica," *Journal of Informatica*, vol 31, pp. 249-268, 2007.
- [48] V. Vapnik and C. Cortes, "Support-vector networks," *Machine learning*, vol. 20, no. 3, pp. 273-297, 1995.
- [49] Yi Wang and Hexiang Duan, "Classification of Hyperspectral Images by SVM Using a Composite Kernel by Employing Spectral, Spatial and Hierarchical Structure Information," *IEEE journal of selected topics in applied earth observations and remote sensing*, vol. 10, no. 3, pp. 441, 2018.
- [51] I. Jolliffe, *Principal Component Analysis*, John Wiley & Sons, 2011.
- [52] T. Subba and J. Harikiran, "VM-Based Learning Algorithms for Classification of Power Quality Disturbances," in *In Proceedings of the 4th International Conference on Inventive Systems and Control (ICISC 2020)* , 2020.
- [53] S. Patra and L. Bruzzone, "A Novel SOM-SVM-Based Active Learning Technique for Remote Sensing Image Classification," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, no. 11, pp. 6899-6910, 2014
- [54] D. D and Champeneri, "Transforming Fruit Farming in a hi tech way through remote sensing : a review," *Journal of remote sensing* vol. 15, pp. 333-341, 2023.