

**KLASIFIKASI CITRA HIPERSPEKTRAL PADA  
TUTUPAN LAHAN MENGGUNAKAN METODE 3D  
*CONVOLUTIONAL NEURAL NETWORK***



**OLEH :  
YESINTA FLORENSIA  
09042681721003**

**PROGRAM STUDI MAGISTER ILMU KOMPUTER  
FAKULTAS ILMU KOMPUTER  
UNIVERSITAS SRIWIJAYA  
2022**

**KLASIFIKASI CITRA HIPERSPEKTRAL PADA  
TUTUPAN LAHAN MENGGUNAKAN METODE 3D  
*CONVOLUTIONAL NEURAL NETWORK***

**TESIS**

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



**OLEH :  
YESINTA FLORENSIA  
09042681721003**

**PROGRAM STUDI MAGISTER ILMU KOMPUTER  
FAKULTAS ILMU KOMPUTER  
UNIVERSITAS SRIWIJAYA  
2022**

**LEMBAR PENGESAHAN**

**KLASIFIKASI CITRA HIPERSPEKTRAL PADA  
TUTUPAN LAHAN MENGGUNAKAN METODE 3D  
CONVOLUTIONAL NEURAL NETWORK**

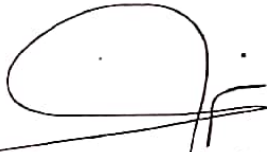
**TESIS**

Diajukan Untuk Melengkapi Salah Satu Syarat  
Memperoleh Gelar Magister

**OLEH :**  
**YESINTA FLORENSIA**  
**09042681721003**

**Palembang, September 2022**

**Pembimbing I**



**Prof. Drs. Saparudin, M.T., Ph.D.**  
**NIP. 196904121995021001**

**Pembimbing II**



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

**Mengetahui,**  
**Koordinator Program Studi Magister Ilmu Komputer**



**Dian Palupi Rini, M.Kom., Ph.D.**  
**NIP. 19780223200604002**

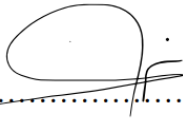
## HALAMAN PERSETUJUAN

Pada hari Senin tanggal 26 Juli 2021 telah dilaksanakan ujian sidang tesis oleh Magister Ilmu Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.

Nama : Yesinta Florensia  
NIM : 09042681721003  
Judul : Klasifikasi Citra Hiperspektral Pada Tutupan Lahan Menggunakan Metode 3D *Convolutional Neural Network*

1. Pembimbing I

Prof. Drs. Saparudin, M.T., Ph.D.  
NIP. 196904121995021001



.....

2. Pembimbing II

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



.....

3. Penguji I

Dr. Ir. Bambang Tutuko, M.T.  
NIP. 196904121995021001



.....

4. Penguji II

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



.....

Mengetahui,  
Koordinator Program Studi Magister Ilmu Komputer



Dian Palupi Rini, M.Kom., Ph.D.  
NIP. 197802232006042002

## LEMBAR PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : Yesinta Florensia  
NIM : 09042681721003  
Program Studi : Magister Ilmu Komputer  
Judul Tesis : Klasifikasi Citra Hiperspektral Pada Tutupan Lahan Menggunakan Metode 3D *Convolutional Neural Network*

Hasil Pengecekan Software iThenticate/Turnitin : **18 %**

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

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



Palembang, September 2022



Yesinta Florensia

NIM. 09042681721003

## KATA PENGANTAR

Puji dan syukur penulis haturkan kehadirat Allah Subhanahu wa ta'ala yang telah mengaruniakan rahmat, hidayah dan memberikan kesempatan bagi penulis untuk menyelesaikan tesis yang berjudul “**Klasifikasi Citra Hiperspektral Pada Tutupan Lahan Menggunakan Metode 3D Convolutional Neural Network**”, yang disusun sebagai syarat untuk memperoleh gelar magister pada Program Studi Magister Ilmu Komputer Universitas Sriwijaya.

Pada kesempatan ini penulis ingin menyampaikan ucapan terima kasih kepada pihak-pihak yang telah membantu, memberikan dukungan serta bimbingan dalam proses penyelesaian tesis ini, diantaranya :

1. Kedua orang tua, Bapak dan Mama serta ketiga saudaraku yang tidak henti-hentinya terus memberikan semangat, motivasi dan doa.
2. Ibu Dian Palupi Rini, S.Si., M.Kom., Ph.D. selaku Koordinator Program Studi Magister Ilmu Komputer.
3. Bapak Prof. Drs. Saparudin, M.T., Ph.D. dan Bapak Samsuryadi, S.Si., M.Kom., Ph.D. selaku pembimbing yang terus memberikan kritik, saran, bantuan dan meluangkan waktu dalam proses penyelesaian tesis ini.
4. Bapak Dr. Ir. Sukemi, M.T. selaku ketua sidang.
5. Bapak Dr. Ir. Bambang Tutuko, M.T. dan Bapak Dr. Yusuf Hartono, M.Sc. selaku penguji.
6. Semua Dosen Magister Ilmu Komputer Universitas Sriwijaya yang telah memberikan ilmu kepada penulis selama proses perkuliahan
7. Admin dan seluruh teman-teman di lingkungan Magister Ilmu Komputer yang telah banyak membantu dan memberikan semangat kepada penulis.

Penulis menyadari berbagai kekurangan dalam penulisan tesis ini, baik dari segi isi maupun penulisan. Kritik dan saran sangat diharapkan untuk menghasilkan penelitian yang lebih baik lagi ke depannya. Semoga tesis ini dapat memberikan

kontribusi dan manfaat bagi semua pihak khususnya mahasiswa Magister Ilmu  
Komputer Universitas Sriwijaya.

Palembang, September 2022

Penulis

# **HYPERSPECTRAL IMAGE CLASSIFICATION ON LAND COVER USING 3D CONVOLUTIONAL NEURAL NETWORK**

## **Abstract**

Land cover with hyperspectral satellite imagery can provide accurate information in the earth surface monitoring activities. Various studies have been developed on the land cover hyperspectral imagery classification, but limited public data is an obstacle in determining the right classification model. Several studies validate model performance by testing with large test data and very limited training samples and extreme data imbalance. However, these studies have complicated model structures and suboptimal performance. This study uses a method with a simpler structure and shallower network, by combining HybridSN, 3D dilated convolution and MSR3DCNN which were tested on two datasets Indian Pines (IP) and Salinas (SA). The test results showed that the combination of HybridSN and 3D dilated convolution obtained the highest accuracy compared to the HybridSN-MSR3DCNN combination as well as other studies with the same number of test samples, with OA accuracy of 96.58%, kappa 96.09% on the IP dataset and AA accuracy of 99.08%, kappa 99.00% on the SA dataset.

**Keyword** : Land Cover, Hyperspectral, 3D Convolutional Neural Network, Dilated Convolution



# KLASIFIKASI CITRA HIPERSPEKTRAL PADA TUTUPAN LAHAN MENGGUNAKAN 3D CONVOLUTIONAL NEURAL NETWORK

## Abstrak

Tutupan lahan dengan citra satelit hiperspektral dapat memberikan informasi akurat dalam aktivitas pemantauan permukaan bumi. Berbagai penelitian dikembangkan pada klasifikasi citra hiperspektral tutupan lahan, namun data publik yang terbatas menjadi kendala dalam menentukan model klasifikasi yang tepat. Beberapa penelitian memvalidasi kinerja model dengan melakukan pengujian dengan data uji yang besar dan sampel pelatihan yang sangat terbatas serta ketimpangan data yang ekstrem. Namun penelitian-penelitian tersebut memiliki struktur model yang rumit dan kinerja yang belum optimal. Penelitian ini menggunakan metode dengan struktur yang lebih sederhana dan jaringan yang lebih dangkal, dengan mengkombinasikan HybridSN, 3D *dilated convolution* dan MSR3DCNN yang diuji pada dua dataset Indian Pines (IP) dan Salinas (SA). Hasil pengujian memperlihatkan kombinasi HybridSN dan 3D *dilated convolution* memperoleh akurasi tertinggi dibandingkan kombinasi HybridSN-MSR3DCNN serta penelitian lain dengan jumlah sampel pengujian yang sama, dengan akurasi OA 96,58%, kappa 96.09% pada dataset IP dan akurasi AA 99,08%, kappa 99,00% pada dataset SA.

**Kata Kunci** : Tutupan Lahan, Hiperspektral, 3D *Convolutional Neural Network*, *Dilated Convolution*

## DAFTAR ISI

	Halaman
<b>HALAMAN JUDUL</b>	<b>i</b>
<b>HALAMAN PENGESAHAN</b>	<b>ii</b>
<b>HALAMAN PERSETUJUAN</b>	<b>iii</b>
<b>LEMBAR PERNYATAAN</b>	<b>iv</b>
<b>KATA PENGANTAR</b>	<b>v</b>
<b>ABSTRACT</b>	<b>vii</b>
<b>ABSTRAK</b>	<b>viii</b>
<b>DAFTAR ISI</b>	<b>ix</b>
<b>DAFTAR GAMBAR</b>	<b>xi</b>
<b>DAFTAR TABEL</b>	<b>xiii</b>
<b>DAFTAR LAMPIRAN</b>	<b>xiv</b>
<b>BAB I PENDAHULUAN</b>	<b>1</b>
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	6
1.5 Batasan Masalah	6
1.6 Sistematika Penulisan	6
<b>BAB II TINJAUAN PUSTAKA</b>	<b>8</b>
2.1 Penelitian Rujukan	8
2.2 Penelitian Klasifikasi Citra Hiperspektral Pada Tutupan Lahan dengan Sampel Terbatas	10
2.3 Penginderaan Jauh	10
2.4 Spektrum Elektromagnetik	11
2.5 Penginderaan Jauh Hiperspektral	12
2.6 Tutupan lahan	15
2.7 Praproses Data	17
2.8 Klasifikasi Citra Hiperspektral	20
2.8.1 <i>Convolutional Neural Network</i> (CNN)	20
2.8.1.1 Arsitekur CNN	20
2.8.2 <i>Dropout</i>	23
2.8.3 Softmax Classifier	25
2.8.4 DiffGrad Optimizer	25
2.8.5 Proses Pembelajaran <i>Convolutional Neural Network</i> (CNN)	26
2.8.6 <i>Three Dimensional Convolutional Neural Network</i> (3D CNN)	28
2.8.7 <i>Hybrid Sepctral Convolutional Neural Network</i> (HybridSN)	29
2.8.8 <i>Multiple Spectral Resolution 3D Convolutional Neural Network</i> (MSR3DCNN)	30

2.8.8.1 <i>Residual Connection</i>	31
2.8.8.2 <i>Dilated Convolution</i>	32
2.9 Metode Evaluasi	34
<b>BAB III METODOLOGI PENELITIAN</b>	<b>37</b>
3.1 Pengumpulan Data	38
3.1.1 Analisis Data	38
3.1.2 Praproses Data	41
3.2 Proses Klasifikasi	43
3.3 Ekstraksi Fitur dan Klasifikasi	47
3.4 Arsitektur MSR3DCNN dan HybridSN	48
3.5 Evaluasi	50
3.6 Hasil Pengujian	52
3.7 Analisis dan Kesimpulan	52
<b>BAB IV HASIL DAN PEMBAHASAN</b>	<b>53</b>
4.1 Hasil Pengujian Pada Dataset Indian Pines (IP) dan Salinas (SA)	53
4.1.1 Hasil Pengujian Model 1	53
4.1.2 Model 2	56
4.1.3 Model 3	59
4.1.4 Model 4	62
4.1.5 Model 5	65
4.1.6 Model 6	68
4.1.7 Evaluasi Perbandingan Kinerja Model Pada Dataset Indian Pines (IP)	71
4.1.8 Evaluasi Perbandingan Kinerja Model Pada Dataset Salinas (SA)	73
4.1.9 Perbandingan Kinerja Model Pada Dataset IP dan SA	76
4.2 Studi Perbandingan	78
4.2.1 Pengujian dan Perbandingan Pada 10% Data Latih	80
<b>BAB V KESIMPULAN DAN SARAN</b>	<b>82</b>
5.1 Kesimpulan	82
5.2 Saran	83
<b>DAFTAR PUSTAKA</b>	<b>84</b>

## DAFTAR GAMBAR

	Halaman
<b>Gambar 2.1</b> Sistem Penginderaan Jauh dan Aplikasinya	11
<b>Gambar 2.2</b> Kurva Pantulan Spektral	12
<b>Gambar 2.3</b> Spektrum Elektromagnetik	13
<b>Gambar 2.4</b> Konsep Hiperspektral	14
<b>Gambar 2.5</b> Arsitektur CNN Secara Umum	21
<b>Gambar 2.6</b> Proses Operasi Konvolusi	22
<b>Gambar 2.7</b> Jaringan Standar dan Jaringan Dengan <i>Dropout</i>	24
<b>Gambar 2.8</b> Arsitektur 3D CNN	29
<b>Gambar 2.9</b> Arsitektur HybridSN	30
<b>Gambar 2.10</b> Arsitektur MSR 3D CNN	31
<b>Gambar 2.11</b> <i>Residual Connection</i>	32
<b>Gambar 2.12</b> Dilated Convolution pada 2D CNN	32
<b>Gambar 2.13</b> <i>Dilated Convolution</i> Pada 3D CNN	33
<b>Gambar 3.1</b> Tahapan Penelitian	37
<b>Gambar 3.2</b> False Color dan Groundtruth Dataset Indian Pines (IP)	40
<b>Gambar 3.3</b> False Color dan Groundtruth Dataset Salinas (SA)	41
<b>Gambar 3.4</b> Praproses Data	41
<b>Gambar 3.5</b> Implementasi PCA Pada Citra Hiperspektral	42
<b>Gambar 3.6</b> Implementasi Augmentasi Data	43
<b>Gambar 3.7</b> Tahapan Klasifikasi Citra Hiperspektral Pada Tutupan Lahan	44
<b>Gambar 3.8</b> Ilustrasi Klasifikasi Citra Hiperspektral Tutupan Lahan	47
<b>Gambar 3.9</b> Usulan Kombinasi metode MSR3DCNN dan HybridSN	49
<b>Gambar 3.10</b> Usulan Kombinasi Arsitektur SDC dan HybridSN	49
<b>Gambar 3.11</b> Confusion Matrix Pengujian Pada 30% Data Uji	50
<b>Gambar 4.1</b> Kurva Akurasi Hasil Data Latih dan Data Uji dari Model 1	54
<b>Gambar 4.2</b> Kurva Loss Hasil Data Latih dan Data Uji dari Model 1	55
<b>Gambar 4.3</b> Confusion Matrix Model 1 Pada Dataset IP	55
<b>Gambar 4.4</b> Confusion Matrix Model 1 Pada Dataset SA	56
<b>Gambar 4.5</b> Kurva Akurasi Hasil Data Latih dan Data Uji dari Model 2	57
<b>Gambar 4.6</b> Kurva Loss Hasil Data Latih dan Data Uji dari Model 2	58
<b>Gambar 4.7</b> Confusion Matrix Model 2 Pada Dataset IP	58
<b>Gambar 4.8</b> Confusion Matrix Model 2 Pada Dataset SA	59
<b>Gambar 4.9</b> Kurva Akurasi Hasil Data Latih dan Data Uji dari Model 3	60
<b>Gambar 4.10</b> Kurva Loss Hasil Data Latih dan Data Uji dari Model 3	61
<b>Gambar 4.11</b> Confusion Matrix Model 3 Pada Dataset IP	61
<b>Gambar 4.12</b> Confusion Matrix Model 3 Pada Dataset SA	62
<b>Gambar 4.13</b> Kurva Akurasi Hasil Data Latih dan Data Uji dari Model 4	63
<b>Gambar 4.14</b> Kurva Loss Hasil Data Latih dan Data Uji dari Model 4	64

<b>Gambar 4.15</b> Confusion Matrix Model 4 Pada Dataset IP	64
<b>Gambar 4.16</b> Confusion Matrix Model 4 Pada Dataset IP	65
<b>Gambar 4.17</b> Kurva Akurasi Hasil Data Latih dan Data Uji dari Model 5	66
<b>Gambar 4.18</b> Kurva Loss Hasil Data Latih dan Data Uji dari Model 5	67
<b>Gambar 4.19</b> Confusion Matrix Model 5 Pada Dataset IP	67
<b>Gambar 4.20</b> Confusion Matrix Model 5 Pada Dataset SA	68
<b>Gambar 4.21</b> Kurva Akurasi Hasil Data Latih dan Data Uji dari Model 6	69
<b>Gambar 4.22</b> Kurva Loss Hasil Data Latih dan Data Uji dari Model 6	69
<b>Gambar 4.23</b> Confusion Matrix Model 6 Pada Dataset IP	70
<b>Gambar 4.24</b> Confusion Matrix Model 6 Pada Dataset SA	71
<b>Gambar 4.25</b> Perbandingan <i>Groundtruth</i> dan Peta Hasil Klasifikasi Model 1 – Model 6 Pada Dataset IP	73
<b>Gambar 4.26</b> Perbandingan <i>Groundtruth</i> dan Peta Hasil Klasifikasi Model 1 – Model 6 Pada Dataset SA	75
<b>Gambar 4.27</b> Perbandingan Akurasi AA, OA dan Kappa Dari Masing-Masing Model Yang Diuji Pada Dataset IP dan SA	76

## DAFTAR TABEL

	Halaman
<b>Tabel 2.1</b> Jenis Citra Hiperspektral	14
<b>Tabel 2.1</b> Ilustrasi Perhitungan Kappa Coefficient Pada Confusion Matrix	36
<b>Tabel 3.1</b> Spesifikasi Dataset yang Digunakan	38
<b>Tabel 3.2</b> Kelas Dataset Indian Pines (IP)	39
<b>Tabel 3.3</b> Kelas Dataset Salinas (SA)	40
<b>Tabel 3.4</b> Jumlah Data Latih Setelah Proses <i>Over Sampling</i>	42
<b>Tabel 3.5</b> Jumlah Band Spektral Setelah Reduksi Dimensi	43
<b>Tabel 3.6</b> Arsitektur HybridSN Standar	45
<b>Tabel 3.7</b> Arsitektur <i>Multiple Spectral Resolution</i> (MSR) Yang Akan Digunakan Pada Penelitian Ini	45
<b>Tabel 3.8</b> Hyperparameter Model CNN	46
<b>Tabel 3.9</b> Beberapa Percobaan Kombinasi Metode	46
<b>Tabel 4.1</b> Akurasi Model 1 Pada Dataset IP dan SA	53
<b>Tabel 4.2</b> Akurasi Model 1 Pada Dataset IP dan SA	56
<b>Tabel 4.3</b> Akurasi Model 3 pada Dataset IP dan SA	59
<b>Tabel 4.4</b> Akurasi Model 3 pada Dataset IP dan SA	62
<b>Tabel 4.5</b> Akurasi Model 3 pada Dataset IP dan SA	65
<b>Tabel 4.6</b> Akurasi Model 3 pada Dataset IP dan SA	68
<b>Tabel 4.7</b> Perbandingan Akurasi tiap Model Pada Dataset Indian Pines (IP)	72
<b>Tabel 4.8</b> Perbandingan Akurasi tiap Model Pada Dataset Salinas (SA)	74
<b>Tabel 4.9</b> Perbandingan Dengan Penelitian Sebelumnya Pada Dataset IP	79
<b>Tabel 4.10</b> Perbandingan Dengan Penelitian Sebelumnya Pada Dataset SA	80
<b>Tabel 4.11</b> Perbandingan Dengan Metode MSR3DCNN Pada Dataset IP	80
<b>Tabel 4.10</b> Perbandingan Dengan Metode MSR3DCNN Pada Dataset SA	81

## **DAFTAR LAMPIRAN**

**Lampiran 1** Kartu Konsultasi Tesis II

**Lampiran 2** Form Perbaikan Ujian Tesis II

**Lampiran 3** Jurnal Penelitian

# BAB I PENDAHULUAN

## 1.1 Latar Belakang Masalah

Dalam perkembangan suatu wilayah terjadi perubahan penampakan secara fisik, baik dipengaruhi oleh faktor manusia maupun faktor alam. Informasi tutupan lahan yang akurat merupakan faktor penting dalam memahami fenomena-fenomena yang terjadi di permukaan bumi dan menjadi dasar dalam rencana pengelolaan berbasis lahan (Kosasih dkk, 2019). Pemantauan tutupan lahan secara manual membutuhkan dana besar dan waktu yang lama. Teknologi penginderaan jauh (inderaja) dimanfaatkan untuk mengidentifikasi, memantau, dan mengevaluasi tutupan lahan, sebagai dasar penelitian dalam pemanfaatan lahan tersebut. Dengan memanfaatkan data penginderaan jauh, wilayah yang sulit untuk diakses oleh penduduk sekalipun dapat terdeteksi dengan akurat dan cukup baik tanpa kontak langsung dengan objek atau daerah tersebut, sehingga dapat meminimalkan dana dan waktu yang dibutuhkan (Liang et al., 2017).

Data inderaja memiliki beragam jenis diantaranya citra optik, fotografik maupun nonfotografik yang diperoleh menggunakan sensor satelit dan pesawat. Dari beberapa citra tersebut, citra hiperpektral merupakan citra nonfotografik yang dapat memberikan informasi permukaan bumi secara akurat. Hal ini disebabkan citra ini memiliki puluhan hingga ratusan band spektral dengan spektrum sempit serta resolusi spasial dengan skala besar yang dapat mengidentifikasi susunan senyawa kimiawi objek pada permukaan bumi (Putra & Handoyo, 2013). Berbagai penelitian klasifikasi citra hiperspektral pada tutupan lahan telah banyak dilakukan. Penelitian oleh Stavrakoudis dkk (2012) menggunakan metode *genetic fuzzy rule* untuk mengklasifikasi tutupan lahan dengan citra dari sensor *hyperion Earth Observation* (EO)-1. Penelitian yang dilakukan Petropoulos dkk (2012) pada data *hyperion* EO-1 menerapkan metode fitur ekstraksi *Minimum Noise Fraction* (MNF) dan *Support Vector Machine* (SVM) sebagai pengklasifikasi. Seiring perkembangan zaman, kebutuhan akan keakuratan data semakin meningkat (Li dkk, 2017). Citra inderaja dari sensor pesawat memegang peranan vital pada klasifikasi



citra hiperspektral tutupan lahan karena dapat memberikan informasi permukaan bumi secara lebih detail. Citra ini memiliki resolusi spasial yang tinggi dan skala citra yang lebih besar dibanding citra sensor satelit (Rangnekar dkk, 2020), unggul dalam kinerja dengan suasana berawan, dan pemeliharaan di dalam pesawat dibandingkan pencitra serupa dengan platform satelit (Jia dkk, 2020).

Beberapa penelitian klasifikasi citra hiperspektral tutupan lahan menggunakan citra dengan sensor pesawat. Wang dkk (2017) mengimplementasikan metode *semisupervised active learning* untuk melatih data yang tidak berlabel guna meningkatkan akurasi pada klasifikasi tutupan lahan dengan citra sensor pesawat AVIRIS. Penelitian oleh Windrim dkk (2018) menerapkan pre training pada CNN. Roy dkk (2020) menggunakan kombinasi *Convolutional Neural Network* (CNN) tiga dimensi (3D CNN) dan dua dimensi (2D CNN) untuk mengekstrak fitur spektral dan spasial secara bersamaan, sekaligus mengurangi kompleksitas model dibandingkan dengan menggunakan 3D CNN saja. Namun model yang digunakan pada penelitian-penelitian tersebut belum teruji untuk menangani ketimpangan dan keterbatasan sampel yang umum terjadi pada data penginderaan jauh hiperspektral.

Penelitian lainnya melakukan pengujian klasifikasi citra hiperspektral tutupan lahan dengan set pelatihan yang sangat kecil. Hal ini dilakukan untuk membuat metode yang stabil terhadap ketimpangan dan keterbatasan data pada citra hiperspektral tutupan lahan. Beberapa penelitian di bawah ini diuji pada 500 sampel data latih. Penelitian oleh Zhang dkk (2018) menggunakan CNN dengan memanfaatkan gabungan representasi citra dari wilayah yang beragam (*diverse region*). Metode ini diuji pada dataset Indian Pines (IP) dan Salinas (SA) dengan Overall Accuracy (OA) masing-masing sebesar 88,74% dan 93,46%. Zhu dkk (2019) melakukan perbandingan kinerja tiga metode *Group Intelligence* (GI) yaitu *Genetic Algorithm* (GA), *Particle Swarm Optimization* (PSO) dan *Artificial Bee Colony* (ABC) dalam mengoptimasi metode *Support Vector Machine* (SVM). Akurasi tertinggi diperoleh kombinasi metode GA dan SVM dengan OA sebesar 81,90% pada dataset IP dan OA sebesar 93,14% pada dataset SA. Penelitian oleh Cao dkk (2020) mengusulkan ekstraksi fitur hiperspektral dengan 3D *Discrete*

*Wavelet Transform* (3DWT) yang diklasifikasi menggunakan CNN dengan *active learning strategy*, kemudian dioptimasi dengan *Markov Random Field* (MRF). Metode ini memperoleh akurasi OA sebesar 91,98% dan *Average Accuracy* (AA) sebesar 80,34% pada dataset IP. Penelitian oleh Ge dkk (2020) memanfaatkan tiga jaringan kombinasi 3D-2D CNN dengan ukuran kernel konvolusi berbeda (*multiscale*) yang digabungkan sebelum *fully connected layer*. *Multiscale* yang diterapkan pada kombinasi 3D-2D CNN ini terbukti dapat memberikan fitur diskriminatif dan meningkatkan kinerja model. Pengujian pada dataset IP menghasilkan akurasi OA sebesar 96,07%, AA 94,14% dan kappa 95,51%. Wang dkk (2020) menggunakan metode *Long Short Term Memory* (LSTM) multiskala untuk memperoleh fitur yang variatif, menghasilkan akurasi OA 88,25%, AA 89,48% dan kappa 86,50% pada dataset IP, sedangkan pada dataset SA diperoleh akurasi OA 91,63%, AA 94,58% dan kappa 93,15%. Namun penelitian-penelitian tersebut memiliki parameter yang rumit dan hasil yang diperoleh belum optimal.

Penelitian oleh Xu dkk (2021) memperoleh akurasi yang tinggi pada klasifikasi tutupan lahan dengan 10% sampel pelatihan. Xu mengusulkan metode *Multiple Spectral Resolution 3D Convolutional Neural Network* (MSR3DCNN), merupakan kombinasi dari *Multiple Spectral Resolution* (MSR) yang diadaptasi dari *multiscale fusion*, *3D Spectral Dilated Convolution* (SDC) yang diadaptasi dari *dilated convolution 2D* dan *residual connection*. Dalam penelitian ini diimplementasikan *dilated convolution* pada CNN tiga dimensi dengan ukuran kernel yang berbeda untuk mendapatkan informasi yang variatif. Residual network dimanfaatkan untuk mengatasi *gradient disappearance* dan *gradient explosion* pada jaringan yang dalam. Metode ini digunakan untuk mengurangi ketergantungan pada fitur spasial, dimana pada beberapa kasus, resolusi spasial yang berbeda berdampak pada kinerja metode. Pengujian pada 10% sampel data latih menghasilkan akurasi masing-masing sebesar 98,10% untuk dataset Indian Pines (IP) dan 99,96% pada dataset Salinas (SA).

Berdasarkan uraian di atas, pada penelitian ini akan dilakukan kombinasi metode MSR3DCNN dan HybridSN, dimana metode MSR3DCNN memperoleh akurasi yang tinggi pada klasifikasi tutupan lahan hiperspektral dengan 10% data

latih namun memiliki jaringan yang dalam (*deep*), sedangkan metode HybridSN memperoleh akurasi tinggi pada 30% data latih dengan jaringan yang lebih sederhana. Dikarenakan metode MSR3DCNN memiliki kompleksitas yang cukup tinggi, kombinasi metode pada penelitian ini akan dilakukan dengan dua cara. Pertama dilakukan kombinasi MSR3DCNN-HybridSN dan kedua menerapkan langsung metode SDC yang diadaptasi dari metode MSR3DCNN pada metode HybridSN. Dari kombinasi metode tersebut, akan dilakukan analisis hasil untuk menentukan model mana yang memiliki kinerja terbaik, dan diharapkan dapat meningkatkan akurasi klasifikasi citra hiperspektral tutupan lahan pada sampel terbatas dengan kompleksitas model yang rendah.

## 1.2 Rumusan Masalah

Penggunaan sampel terbatas pada klasifikasi citra hiperspektral tutupan lahan mempengaruhi akurasi. Dari beberapa model yang ada hasil yang diperoleh belum maksimal. Metode *Hybrid Spectral Convolutional Neural Network* (HybridSN) memiliki kompleksitas rendah dan menghasilkan akurasi yang tinggi pada klasifikasi citra hiperspektral tutupan lahan. Metode *Multiple Spectral Resolution 3D Convolutional Neural Network* (MSR3DCNN) terdiri dari metode *3D Spectral Dilated Convolution* (SDC) dengan ukuran kernel yang berbeda dan memiliki koneksi langsung antara input dan output blok. Metode ini memperoleh akurasi yang tinggi pada klasifikasi citra hiperspektral tutupan lahan dengan sampel 10%. Penulis akan melakukan dua kombinasi metode yaitu MSR3DCNN dan HybridSN serta kombinasi SDC dan HybridSN untuk meningkatkan akurasi pada klasifikasi citra hiperspektral tutupan lahan dengan sampel pelatihan terbatas. Berdasarkan penjelasan tersebut, maka dapat dirumuskan beberapa pertanyaan penelitian sebagai berikut:

1. Bagaimana kerangka kerja *Multiple Spectral Resolution 3D Convolutional Neural Network* (MSR3DCNN) dan *Spectral Dilated Convolution* (SDC) yang dikombinasikan dengan metode *Hybrid Spectral Convolutional Neural Network* (HybridSN)?

2. Bagaimana meningkatkan akurasi pada klasifikasi citra hiperspektral tutupan lahan dengan sampel terbatas menggunakan *Multiple Spectral Resolution 3D Convolutional Neural Network* (MSR3DCNN) dan *Spectral Dilated Convolution* (SDC) yang dikombinasikan dengan metode *Hybrid Spectral Convolutional Neural Network* (HybridSN)?
3. Bagaimana pengaruh penggunaan kombinasi *Multiple Spectral Resolution 3D Convolutional Neural Network* (MSR3DCNN) dan *Hybrid Spectral Convolutional Neural Network* (HybridSN) serta kombinasi *Spectral Dilated Convolution* (SDC) dan HybridSN dalam klasifikasi citra hiperspektral pada tutupan lahan dengan sampel pelatihan terbatas?

### 1.3 Tujuan Penelitian

Tujuan penelitian ini adalah sebagai berikut :

1. Mengembangkan kerangka kerja yang mengkombinasikan *Multiple Spectral Resolution 3D Convolutional Neural Network* (MSR3DCNN) dan *Spectral Dilated Convolution* (SDC) dan *Hybrid Spectral Convolutional Neural Network* (HybridSN) untuk meningkatkan akurasi pada klasifikasi citra hiperspektral tutupan lahan dengan sampel terbatas.
2. Menganalisis kinerja *Multiple Spectral Resolution 3D Convolutional Neural Network* (MSR3DCNN) dan *Spectral Dilated Convolution* (SDC) yang dikombinasikan dengan metode *Hybrid Spectral Convolutional Neural Network* (HybridSN).
3. Mendapatkan kesimpulan dari kombinasi *Multiple Spectral Resolution 3D Convolutional Neural Network* (MSR3DCNN) dan *Spectral Dilated Convolution* (SDC) dan *Hybrid Spectral Convolutional Neural Network* (HybridSN) pada klasifikasi citra hiperspektral tutupan lahan dengan sampel terbatas.

#### 1.4 Manfaat Penelitian

Manfaat penelitian ini adalah sebagai berikut :

1. Kerangka kerja dapat digunakan sebagai referensi dalam penelitian klasifikasi citra hiperspektral pada tutupan lahan dengan sampel terbatas.
2. Mengetahui kinerja metode kombinasi *Multiple Spectral Resolution 3D Convolutional Neural Network* (MSR3DCNN) dan *Spectral Dilated Convolution* (SDC) dan *Hybrid Spectral Convolutional Neural Network* (HybridSN) pada klasifikasi citra hiperspektral tutupan lahan dengan sampel terbatas.

#### 1.5 Batasan Masalah

Batasan masalah pada penelitian ini adalah sebagai berikut :

1. Data yang digunakan dalam penelitian ini adalah dataset *indian pines* dan *salinas* yang diperoleh dari sensor pesawat AVIRIS.
2. Data telah dinormalisasi dan dilengkapi *groundtruth*.
3. Data latih yang digunakan hanya 5% pada Indian Pines (IP) dan 5% pada Salinas (SA).

#### 1.6 Sistematika Penulisan

Sistematika penulisan tesis secara garis besar dari setiap bab, dinyatakan sebagai berikut:

1. BAB I - PENDAHULUAN

Bab ini membahas tentang latar belakang, rumusan masalah, batasan masalah, tujuan dan manfaat penelitian, metodologi penelitian dan sistematika penulisan.

## 2. BAB II - TINJAUAN PUSTAKA

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

## 3. BAB III – METODOLOGI PENELITIAN

Bab ini berisi penjelasan secara bertahap dan terperinci tentang langkah-langkah (metodologi) yang digunakan untuk membuat kerangka berfikir dan kerangka kerja dalam menyelesaikan proposal tesis.

## 4. BAB IV – HASIL DAN ANALISA

Pada bab ini berisi tentang analisis dan pembahasan dari tiap-tiap diagram perencanaan rangkaian data-data hasil pengukuran dalam penelitian.

## 5. BAB IV – KESIMPULAN

Bab ini memuat kesimpulan dari penelitian yang dilakukan dan menjawab tujuan penelitian yang ada pada bab 1 serta berisi saran yang dapat dilakukan pada penelitian selanjutnya

## DAFTAR PUSTAKA

- Aloysius, N., & Geetha, M. (2018). A review on deep convolutional neural networks. *Proceedings of the 2017 IEEE International Conference on Communication and Signal Processing, ICCSP 2017, 2018-Janua*, 588–592. <https://doi.org/10.1109/ICCSP.2017.8286426>
- Ariza-López, F. J., Rodríguez-Avi, J., & Alba-Fernández, M. v. (2018). Complete control of an observed confusion matrix. *International Geoscience and Remote Sensing Symposium (IGARSS), 2018-July*, 1222–1225. <https://doi.org/10.1109/IGARSS.2018.8517540>
- Badan Standardisasi Nasional. (2010). Klasifikasi Penutup Lahan. *Sni, SNI 7645(2010)*, 28.
- B. Smith, R. (2014). Hyperspectral imaging. *Food Engineering Series*, 199–216. [https://doi.org/10.1007/978-1-4939-0311-5\\_9](https://doi.org/10.1007/978-1-4939-0311-5_9)
- Cao, X., Yao, J., Fu, X., Bi, H., & Hong, D. (2020). An Enhanced 3-D Discrete Wavelet Transform for Hyperspectral Image Classification. *IEEE Geoscience and Remote Sensing Letters*, 18(6), 1104–1108. <https://doi.org/10.1109/lgrs.2020.2990407>
- Dubey, S. R., Chakraborty, S., Roy, S. K., Mukherjee, S., Singh, S. K., & Chaudhuri, B. B. (2019). diffGrad: An Optimization Method for Convolutional Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*. <https://doi.org/10.1109/TNNLS.2019.2955777>
- Ge, Z., Cao, G., & Fu, P. (2020). Hyperspectral Image Classification Method Based on 2D–3D CNN and Multibranch Feature Fusion. *Laser and Optoelectronics Progress*, 57(20), 5776–5788. <https://doi.org/10.3788/LOP57.202803>
- Ge, Z., Cao, G., Li, X., & Fu, P. (2020). Hyperspectral Image Classification Method Based on 2D-3D CNN and Multibranch Feature Fusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 5776–5788. <https://doi.org/10.1109/JSTARS.2020.3024841>
- Ghamisi, P., Plaza, J., Chen, Y., Li, J., & Plaza, A. J. (2017). Advanced Spectral Classifiers for Hyperspectral Images: A review. *IEEE Geoscience and Remote Sensing Magazine*, 5(1), 8–32. <https://doi.org/10.1109/MGRS.2016.2616418>
- Gregorio Di, A., Jaffrain, G., & Louis Weber, J. (2011). Expert Meeting on Ecosystem Accounts 5 - 7. *Meta*, 3, 1–29.

- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, *187*, 27–48. <https://doi.org/10.1016/j.neucom.2015.09.116>
- Ilahiyah, S., & Nilogiri, A. (2018). *Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network*. *3*(2), 49–56.
- Jia, J., Wang, Y., Chen, J., Guo, R., Shu, R., & Wang, J. (2020). Status and application of advanced airborne hyperspectral imaging technology: A review. *Infrared Physics and Technology*, *104*, 103115. <https://doi.org/10.1016/j.infrared.2019.103115>
- Kosasih, D., Buce Saleh, M., & Budi Prasetyo, L. (2019). Visual and Digital Interpretations for Land Cover Classification in Kuningan District, West Java. *Jurnal Ilmu Pertanian Indonesia*, *24*(2), 101–108. <https://doi.org/10.18343/jipi.24.2.101>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Li, W., Wu, G., Member, S., & Zhang, F. (2017). *Hyperspectral Image Classification Using Deep Pixel-Pair Features*. *55*(2), 844–853.
- Li, Y., Zhang, H., & Shen, Q. (2017). Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network. *Remote Sensing*, *9*(1). <https://doi.org/10.3390/rs9010067>
- Loshchilov, I., & Hutter, F. (2019). Decoupled weight decay regularization. *7th International Conference on Learning Representations, ICLR 2019*.
- Olofsson, P., Foody, G. M., Herold, M., Stehman, S. v, Woodcock, C. E., & Wulder, M. A. (2014). Remote Sensing of Environment Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, *148*, 42–57. <https://doi.org/10.1016/j.rse.2014.02.015>
- O'Shea, K., & Nash, R. (2015). *An Introduction to Convolutional Neural Networks*. November. <http://arxiv.org/abs/1511.08458>
- Petropoulos, G. P., Kalaitzidis, C., & Prasad Vadrevu, K. (2012). Support vector machines and object-based classification for obtaining land-use/cover cartography from Hyperion hyperspectral imagery. *Computers and Geosciences*, *41*, 99–107. <https://doi.org/10.1016/j.cageo.2011.08.019>
- Putra, E. H., & Handoyo, E. W. (2013). Kajian teknis penggunaan citra satelit eo-1 hyperion untuk pemetaan habitat terumbu karang di pesisir utara taman



nasional bunaken. *Info BPK Manado*, Volume 3 No.1, 65-78.

- Rangnekar, A., Mokashi, N., Ientilucci, E. J., Kanan, C., & Hoffman, M. J. (2020). AeroRIT: A New Scene for Hyperspectral Image Analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 1–9. <https://doi.org/10.1109/tgrs.2020.2987199>
- Rawat, W., & Wang, Z. (2017). *Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review*. 2449, 2352–2449. <https://doi.org/10.1162/NECO>
- Roy, S. K., Krishna, G., Dubey, S. R., & Chaudhuri, B. B. (2020). HybridSN: Exploring 3-D-2-D CNN Feature Hierarchy for Hyperspectral Image Classification. *IEEE Geoscience and Remote Sensing Letters*, 17(2), 277–281. <https://doi.org/10.1109/LGRS.2019.2918719>
- Rwanga, S. S., & Ndambuki, J. M. (2017). Accuracy Assessment of Land Use/Land Cover Classification Using Remote Sensing and GIS. *International Journal of Geosciences*, 08(04), 611–622. <https://doi.org/10.4236/ijg.2017.84033>
- Sarmiento, P. A. R. (2015). *ERROR AND UNCERTAINTY IN THE ACCURACY ASSESSMENT OF LAND COVER MAPS*. 1–139.
- Srivastava, N., Hinton, G., Krizhevsky, A., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. In *Journal of Machine Learning Research* (Vol. 15).
- Stavroudis, D. G., Galidaki, G. N., Gitas, I. Z., & Theocharis, J. B. (2012). A genetic fuzzy-rule-based classifier for land cover classification from hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 50(1), 130–148. <https://doi.org/10.1109/TGRS.2011.2159613>
- Verhoeven, G. J. J. (2018). The reflection of two fields – Electromagnetic radiation and its role in (aerial) imaging. *AARGnews*, November, 10–18. <https://doi.org/10.5281/zenodo.3534245>
- Wang, Z., Du, B., Zhang, L., Zhang, L., & Jia, X. (2017). A Novel Semisupervised Active-Learning Algorithm for Hyperspectral Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(6), 3071–3083. <https://doi.org/10.1109/TGRS.2017.2650938>
- Wang, Z., Zou, C., & Cai, W. (2020). Small sample classification of hyperspectral remote sensing images based on sequential joint deeping learning model. *IEEE Access*, 8, 71353–71363. <https://doi.org/10.1109/ACCESS.2020.2986267>
- Windrim, L., Melkumyan, A., Murphy, R. J., Chlingaryan, A., & Ramakrishnan, R.

- (2018). Pretraining for Hyperspectral Convolutional Neural Network Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 56(5), 2798–2810. <https://doi.org/10.1109/TGRS.2017.2783886>
- Wiweka. (2008). Kapabilitas citra hiperspektral. *Berita Dirgantara*, 9(3), 55–60.
- Xu, H., Yao, W., Cheng, L., & Li, B. (2021). Multiple spectral resolution 3D convolutional neural network for hyperspectral image classification. *Remote Sensing*, 13(7). <https://doi.org/10.3390/rs13071248>
- Yang, H., Li, S., Chen, J., Zhang, X., & Xu, S. (2017). The Standardization and harmonization of land cover classification systems towards harmonized datasets: A review. *ISPRS International Journal of Geo-Information*, 6(5), 1–16. <https://doi.org/10.3390/ijgi6050154>
- Zabalza, J. (2015). *Feature extraction and data reduction for hyperspectral remote sensing earth observation*. June.
- Zhang, B., Zhao, L., & Zhang, X. (2020). Three-dimensional convolutional neural network model for tree species classification using airborne hyperspectral images. *Remote Sensing of Environment*, 247(June), 111938. <https://doi.org/10.1016/j.rse.2020.111938>
- Zhang, H., Li, Y., Zhang, Y., & Shen, Q. (2017). Spectral-spatial classification of hyperspectral imagery using a dual-channel convolutional neural network. *Remote Sensing Letters*, 8(5), 438–447. <https://doi.org/10.1080/2150704X.2017.1280200>
- Zhang, M., Li, W., & Du, Q. (2018). Diverse region-based CNN for hyperspectral image classification. *IEEE Transactions on Image Processing*, 27(6), 2623–2634. <https://doi.org/10.1109/TIP.2018.2809606>
- Zhu, X., Li, N., & Pan, Y. (2019). Optimization performance comparison of three different group intelligence algorithms on a SVM for hyperspectral imagery classification. *Remote Sensing*, 11(6). <https://doi.org/10.3390/RS11060734>
- Zufar, B. S., & Muhammad. (2016). Convolutional Neural Networks untuk Pengenalan Wajah Secara Real-Time. *Jurnal Sains Dan Seni*, 5(3), 1–6. <https://doi.org/10.1177/0892705705044556>