



Kombinasi 3D Convolutional Neural Network Dalam Klasifikasi Citra Hiperspektral Pada Tutupan Lahan

Yesinta Florensia^{1,*}, Saparudin², Samsuryadi¹

¹ Fakultas Ilmu Komputer, Magister Ilmu Komputer, Universitas Sriwijaya, Palembang, Indonesia

² Fakultas Ilmu Komputer, Universitas Telkom, Bandung, Indonesia

Email: ^{1,*}yesinta.florensia@gmail.com, ²saparudin@telkomuniversity.ac.id, ³samsuryadi@unsri.ac.id

Email Penulis Korespondensi: yesinta.florensia@gmail.com

Abstrak—Informasi tutupan lahan merupakan salah satu variabel dasar dalam menentukan fenomena-fenomena pada permukaan bumi maupun sebagai variabel pengukur pembangunan suatu wilayah. Tutupan lahan dengan citra hiperspektral dapat memberikan informasi permukaan bumi secara akurat. Sampel berlabel terbatas dan ketidakseimbangan data merupakan hal yang umum pada klasifikasi citra hiperspektral tutupan lahan. Namun data yang tersedia secara publik sangat terbatas menyulitkan untuk mengevaluasi kinerja algoritma yang ada. Berbagai metode dikembangkan dengan beberapa dataset publik menggunakan sesedikit mungkin sampel pelatihan untuk menghasilkan metode yang robust terhadap keterbatasan sampel dan ketidakseimbangan data, namun penelitian-penelitian tersebut memiliki parameter rumit dan hasil akurasi belum optimal. Dalam penelitian ini dilakukan beberapa kombinasi dari metode *Multiple Spectral Resolution* (MSR), *3D Spectral Dilated Convolution* (SDC) dan *Hybrid Convolutional Neural Network* (HybridSN), untuk meningkatkan akurasi pada klasifikasi citra hiperspektral dengan sampel pelatihan sangat kecil serta parameter dan komputasi yang lebih sederhana. Metode ini diuji pada dua dataset publik Indian Pines (IP) dan Salinas (SA) dengan masing-masing data latih sebesar 5% dan 1% atau hanya 500 sampel pelatihan dan memperoleh akurasi yang tinggi pada klasifikasi citra hiperspektral pada tutupan lahan. Hasil terbaik diperoleh dengan kombinasi metode SDC dan HybridSN yang dioptimasi dengan Adam dengan *Overall Accuracy* (OA) 96,58% %, *Average Accuracy* (AA) 87,83% dan *kappa* 96,09% pada dataset IP, dan *Average Accuracy* (AA) 99,08% dan *kappa* 99,00% pada dataset SA.

Kata Kunci: Klasifikasi Citra Hiperspektral; Tutupan Lahan; Penginderaan Jauh; 3D Convolutional Neural Network; 3D Dilated Convolution

Abstract—Land cover information is one of the basic variables in determining phenomena on the earth's surface as well as a measuring variable for the development of an area. Land cover with hyperspectral imagery can provide accurate information on the earth's surface. Limited labeled samples and imbalances data are common in land cover hyperspectral image classification. However, the data that available publicly is very limited makes it difficult to evaluate the performance of existing algorithms. Various methods were developed with several public datasets using as few training samples as possible to produce a method that is robust against sample limitations and imbalances data, but these studies have complicated parameters and the accuracy results are not optimal. In this study, several combination of *Multiple Spectral Resolution* (MSR), *3D Spectral Dilated Convolution* (SDC) and *Hybrid Convolutional Neural Network* (HybridSN) were carried out to increase accuracy in hyperspectral image classification with very small training samples and simpler parameters and computations. This method was tested on two public datasets Indian Pines (IP) and Salinas (SA) with 5% and 1% training data respectively (only 500 training samples) and showed high accuracy results in land cover hyperspectral image classification. The best results were obtained with a combination of SDC and HybridSN methods which were optimized with Adam with 96.58% *Overall Accuracy* (OA), 87.83% *Average Accuracy* (AA) and 96.09% *kappa* on the IP dataset, and 99.08% *Average Accuracy* (AA), 99.00% *kappa* on the SA dataset.

Keywords: Hyperspectral Imaging Classification; Land Cover; Remote Sensing; 3D Convolutional Neural Network; 3D Dilated Convolution

1. PENDAHULUAN

Tutupan lahan merupakan variabel dasar untuk mengukur berbagai fenomena yang terjadi pada permukaan bumi seperti perubahan iklim, kerusakan lingkungan, maupun evaluasi pengelolaan lahan dan tata ruang wilayah [1][2]. Untuk dapat memanfaatkan informasi tersebut secara maksimal, digunakan citra penginderaan jauh (inderaja) yang memiliki beragam jenis baik citra optik, foto maupun nonfotografik yang diperoleh melalui sensor satelit dan wahana (pesawat) [3]. Dari beberapa jenis citra inderaja tersebut, citra hiperspektral dengan sensor pesawat merupakan salah satu jenis citra nonfotografik yang memiliki kelebihan karena memiliki resolusi spasial yang tinggi dan skala citra yang lebih besar dibanding citra sensor satelit [4][5], unggul dalam kinerja dengan suasana berawan, dan pemeliharaan di dalam pesawat dibandingkan pencitra serupa dengan platform satelit [6].

Dalam klasifikasi citra hiperspektral tutupan lahan, keterbatasan sampel berlabel merupakan hal yang umum terjadi [7][8]. Namun perbedaan jenis lahan dan ketersediaan data publik menyulitkan dalam evaluasi dan perbandingan kinerja metode [9]. Beberapa penelitian tutupan lahan menggunakan sekecil mungkin data pelatihan dari dataset hiperspektral tutupan lahan dengan sensor pesawat yang tersedia secara publik, untuk menghasilkan metode yang tahan terhadap keterbatasan sampel berlabel dan ketidakseimbangan data. Penelitian oleh Zhang dkk menggunakan metode CNN yang memanfaatkan jaringan dengan wilayah yang berbeda (*diverse region*). Metode ini diuji dengan 5% data latih menghasilkan *Overall Accuracy* (OA) 88,74% pada dataset Indian Pines (IP) dan 93,46% pada dataset Salinas (SA) [10]. Penelitian oleh Zhu dkk menggunakan tiga metode *Group*



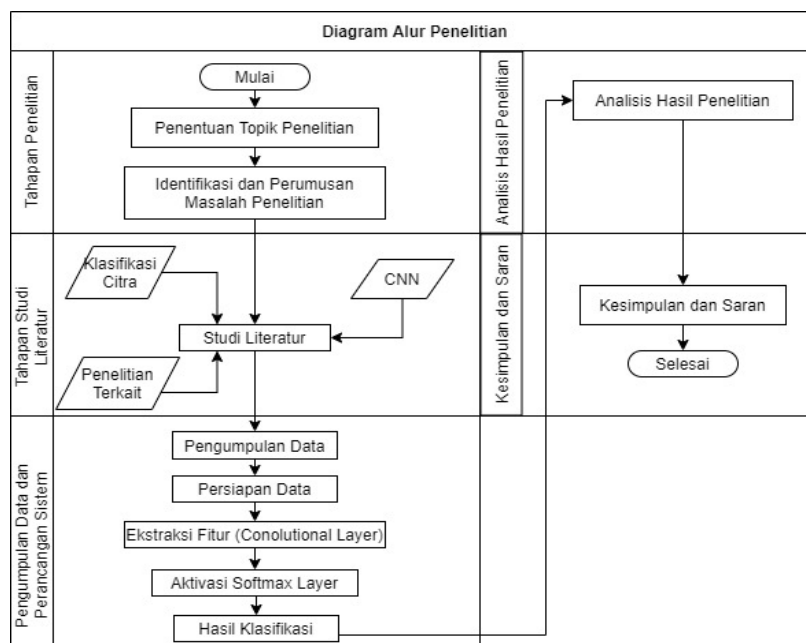
Intelligence (GI) algorithm untuk meningkatkan kinerja metode *Support Vector Machine (SVM)* yaitu *Genetic Algorithm GA*), *Particel Swarm Optimization (PSO)* dan *Artificial Bee Colony (ABC)*. Kombinasi metode GA-SVM memperoleh akurasi OA tertinggi sebesar 81,90% pada dataset IP dan 93,14% pada dataset SA [11]. Cao dkk mengusulkan ekstraksi fitur hiperspektral dengan *3D Discrete Wavelet Transform (3DWT)*, dan CNN dengan *active learning strategy* untuk mengurangi dimensi fitur serta *Markov Random Field (MRF)* sebagai pengklasifikasi. Kombinasi metode ini diuji pada dataset Indian Pines (IP) menghasilkan OA 91,98% dan AA 80,34% [12]. Penelitian oleh Wang dkk menggunakan metode *Long Short Therm Memory (LSTM)* multiskala untuk memperoleh fitur yang variatif menghasilkan akurasi OA 88,25%, AA 89,48% dan kappa 86,50% pada dataset IP dan OA 91,63%, AA 94,58%, kappa 93,15% pada dataset SA [13]. Ge dkk menggunakan *Multibranch Fusion CNN* untuk mengekstrak fitur dengan skala berbeda dan mendapatkan akurasi OA 96,07%, AA 94,14% dan kappa 95,51% pada dataset IP [14]. Namun penelitian-penelitian tersebut memiliki parameter yang rumit dan hasil yang diperoleh belum optimal.

Penelitian Roy dkk menggunakan kombinasi *Convolutional Neural Network (CNN)* tiga dimensi (3D CNN) dan dua dimensi (2D CNN) (*HybridSN*) untuk mengekstrak fitur spektral dan spasial secara bersamaan, sekaligus mengurangi kompleksitas model dibandingkan dengan menggunakan 3D CNN saja, menghasilkan akurasi yang tinggi pada dataset IP dan SA dengan 30% data latih [15]. Xu dkk mengusulkan metode *Multiple Spectral Resolution (MSR)*, merupakan kombinasi 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. 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 IP dan 99,96% pada dataset SA [16].

Metode MSR memperoleh akurasi tinggi pada 90% data uji dengan jaringan yang dalam, sedangkan metode HybrdSN memperoleh akurasi tinggi pada 70% data uji dengan jaringan yang lebih sederhana. Karena itu pada penelitian ini penulis akan melakukan dua percobaan kombinasi, yaitu kombinasi metode MSR dan HybridSN, serta mengimplementasikan langsung metode SDC yang diadaptasi dari MSR pada metode HybridSN untuk menghasilkan model yang lebih sederhana. Hasil dari dua kombinasi tersebut akan dianalisis untuk mengetahui metode mana yang memiliki kinerja terbaik pada klasifikasi tutupan lahan dengan citra hiperspektral. Dari kombinasi metode yang dilakukan pada penelitian ini, diharapkan dapat meningkatkan akurasi klasifikasi citra hiperspektral tutupan lahan pada sampel terbatas dan ketidakseimbangan data dengan kompleksitas model yang rendah.

2. METODOLOGI PENELITIAN

Metodologi penelitian merupakan rangkuman tahapan penelitian secara keseluruhan, tahapan-tahapan tersebut ditunjukkan pada gambar 1.




Gambar 1. Tahapan Penelitian



Pada gambar 1, terdapat beberapa tahapan penelitian dimana tahap pertama merupakan penentuan topik penelitian yang akan diambil, kemudian dilanjutkan dengan proses identifikasi dan merumuskan permasalahan dari penelitian yang akan dilakukan, studi literatur, pengumpulan dan persiapan data, ekstraksi fitur, klasifikasi, memperoleh hasil klasifikasi, analisis hasil serta tahapan terakhir yaitu kesimpulan dan saran.

2.1 Data

Data yang digunakan dalam penelitian ini merupakan citra peta hiperspektral yang dipublikasikan oleh lembaga oleh pusat penelitian dan pengembangan pemerintah Amerika dan *National Aeronautics and Space Administration* (NASA) menggunakan sensor pesawat Airborne Visible/Infrared Imaging Spectrometer (AVIRIS). Ada tiga citra yang digunakan yaitu Indian Pines (IP) terdiri dari 16 kelas, dan Salinas 16 kelas. Gambar 2 menunjukkan citra false color dan groundtruth dari masing-masing citra.



Gambar 2. (a) False color dan groundtruth citra Dioni (b) False color dan groundtruth citra Salinas

Data ini telah dinormalisasi dengan menghapus band penyerapan air, karena dianggap tidak membawa informasi yang berguna dalam proses klasifikasi [17]. Berikut spesifikasi citra peta yang digunakan :

Tabel 1. Spesifikasi citra Dioni

Nama Citra	Ukuran Gambar	Resolusi Spasial	Jumlah Band Spektral
1	Indian Pines	145 x 145	200
2	Salinas	217 x 512	103

Citra IP terdiri dari 16 kelas dengan total sampel sebesar 10249. Data latih yang digunakan pada dataset ini hanya sebesar 5%. Tabel 2 menunjukkan jumlah sampel dari masing-masing kelas.

Tabel 2. Kelas-kelas dan jumlah sampel citra Indian Pines (IP)

No	Kelas	Jumlah Data
1	Alfalfa	46
2	Corn-notill	1428
3	Corn-mintill	830
4	Corn	237
5	Grass-pasture	483
6	Grass-trees	730
7	Grass-pasture-mowed	28
8	Hay-windrowed	478
9	Oats	20
10	Soybean-notill	972
11	Soybean-mintill	2455
12	Soybean-clean	593
13	Wheat	205
14	Woods	1265
15	Buildings-Grass-Trees-Drives	386
16	Stone-Steel-Towers	93
Total		10249

Citra SA terdiri dari 16 kelas dengan total sampel 54129. Data latih yang digunakan pada dataset ini hanya sebesar 1%. Tabel 3 menunjukkan jumlah sampel dari masing-masing kelas .

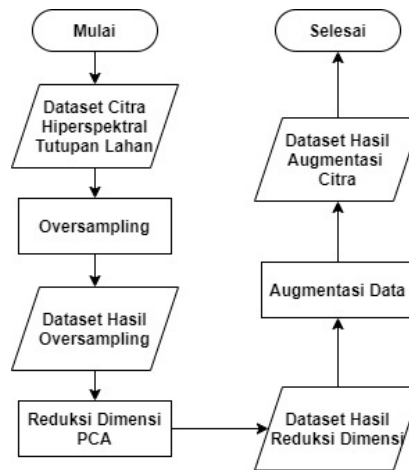


Tabel 3. Kelas-kelas dan jumlah sampel citra Salinas

No	Kelas	Jumlah Data
1	Brocoli_green_weeds_1	2009
2	Brocoli_green_weeds_2	3726
3	Fallow	1976
4	Fallow_rough_plow	1394
5	Fallow_smooth	2678
6	Stubble	3959
7	Celery	3579
8	Grapes_untrained	11271
9	Soil_vinyard_develop	6203
10	Corn_senesced_green_weeds	3278
11	Lettuce_romaine_4wk	1068
12	Lettuce_romaine_5wk	1927
13	Lettuce_romaine_6wk	916
14	Lettuce_romaine_7wk	1070
15	Vinyard_untrained	7268
16	Vinyard_vertical_trellis	1807
Total		54129

2.1.1 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 meliputi *over sampling*, reduksi dimensi dengan *Principal Component Analysis (PCA)* dan augmentasi data. Praproses data ditunjukkan pada gambar 3.

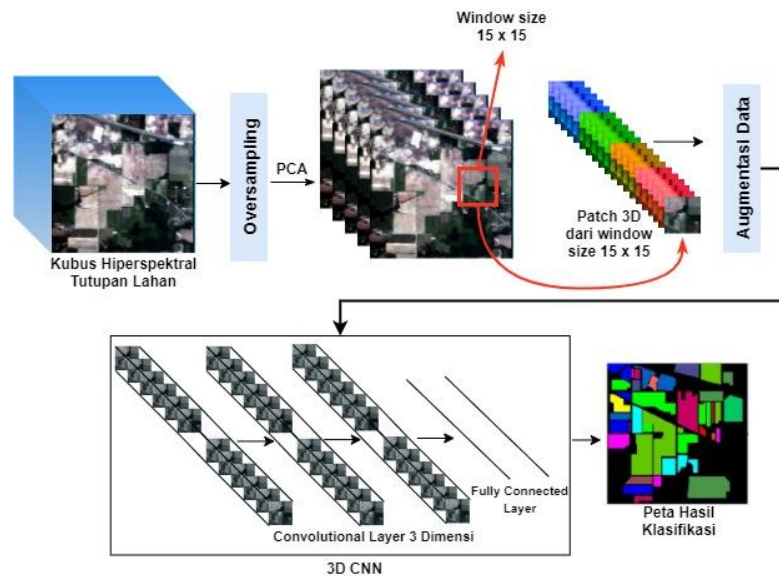


Gambar 3. Tahapan Praproses

Tahap pertama praproses pada penelitian ini adalah oversampling, digunakan untuk menduplikasi data latih pada kelas yang memiliki jumlah sampel sangat kecil. Hal ini dilakukan untuk menghindari *overfitting* pada model karena ketidakseimbangan data [18]. Tahap kedua reduksi dimensi menggunakan metode PCA. Citra hiperspektral memiliki dimensi tinggi karena terdiri dari ratusan bahkan ribuan band spektral, maka sampel yang dibutuhkan untuk membangun klasifikasi yang akurat juga harus ditingkatkan. Sementara citra hiperspektral seringkali memiliki sampel tidak seimbang dan terbatas. Oleh karena itu PCA dimanfaatkan untuk mengurangi dimensi tinggi data dan mengurangi biaya komputasi [19]. Tahap ketiga adalah augmentasi data untuk mengatasi keterbatasan data latih, dimana data latih dimodifikasi dan menghasilkan sekumpulan data latih baru sehingga meningkatkan jumlah data latih yang digunakan [20].

2.2 Proses Klasifikasi

Data citra yang digunakan pada penelitian ini merupakan citra peta yang memiliki dua jenis fitur, yakni fitur spektral dan fitur spasial. Untuk memperoleh kedua fitur tersebut digunakan metode CNN 3 dimensi dengan arsitektur yang berbeda. Akan dilakukan kombinasi dari metode CNN yaitu *Multiple Spectral Resolution (MSR)*, *Spectral Dilated Convolution (SDC)* dan *Hybrid Spectral Convolutional Neural Network (HybridSN)* yang mengekstraksi fitur spektral dan spasial secara bersamaan.

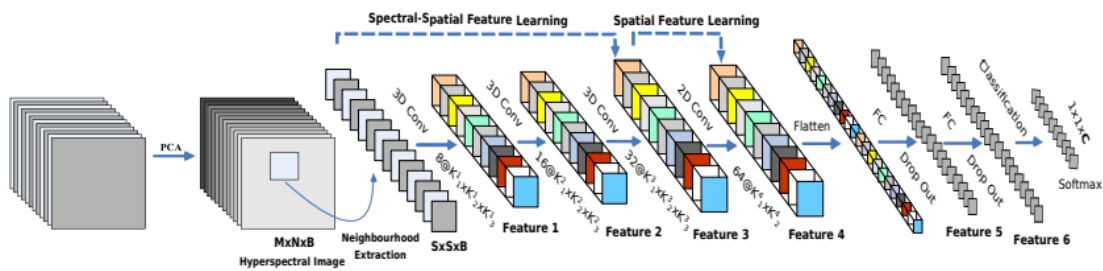


Gambar 4. Ilustrasi Proses Klasifikasi Pada Penelitian Ini

Gambar 4 menunjukkan ilustrasi dari proses klasifikasi dimana kubus hiperspektral yang sudah melalui tahap praproses dengan oversampling, reduksi dimensi dan augmentasi data dipotong menjadi patch 3 dimensi berukuran 15x15 agar dapat diproses sebagai input dari 3D convolutional layer dari metode 3D CNN, dengan hasil akhir klasifikasi berupa *color maps*.

2.2.1 Hybrid Spectral Convolutional Neural Network (HybridSN)

Metode *Hybrid Spectral Convolutional Neural Network* (HybridSN) merupakan gabungan dari *convolutional layer* tiga dimensi (Conv3D) dan dua dimensi (Conv2D). Gabungan dua konvolusi yang berbeda ini dilakukan untuk memperoleh informasi spektral dan spasial dengan komputasi yang rendah. Conv3D pada 3D CNN dapat memperoleh dua jenis fitur yang berbeda dari citra hiperspektral. Sedangkan operasi Conv2D setelahnya dapat menurunkan kompleksitas jika dibandingkan dengan model 3D CNN saja. Arsitektur HybridSN ditunjukkan pada Gambar 5.



Gambar 5. Arsitektur HybridSN [15]

Conv3D mempertahankan korelasi informasi spektral dan spasial dengan menggabungkan data input spektral spasial secara bersamaan. Conv3D mengekstrak kubus hiperspektral dalam bentuk patch tiga dimensi sehingga korelasi dua fitur tidak hilang seperti yang terjadi pada operasi konvolusi satu dimensi dan dua dimensi. Layer-layer dan detail dari arsitektur HybridSN dapat dilihat pada tabel 4.

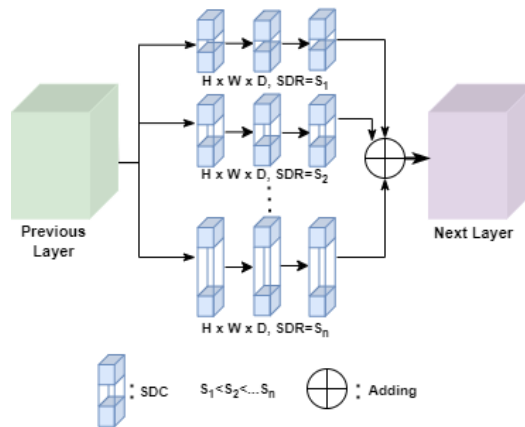
Tabel 4. Detail Arsitektur HybridSN

Layer	Layer Type	Filters	Fungsi Aktivasi	Kernel	Unit
1	Input				
2	Conv_layer1 (Conv3D)	8	Relu	3, 3, 7	
3	Conv_layer2 (Conv3D)	16	Relu	3, 3, 5	
4	Conv_layer3 (Conv3D)	32	Relu	3, 3, 3	
5	Conv_layer4 (Conv2D)	64	Relu	3, 3	
6	Dense layer				256
7	Dropout				
8	Dense layer				128
9	Dropout				



2.2.2 Multiple Spectral Resolution (MSR)

Metode ini terdiri dari gabungan beberapa teknik seperti *Multiple Spectral Resolution (MSR)*, *3D Spectral Dilated Convolution (SDC)* dan *residual connection*. MSR merupakan pengembangan dari teknik *multiscale feature* dimana beberapa kernel dengan ukuran yang berbeda digunakan untuk memperoleh informasi citra pada tingkat yang berbeda. *SDC dilated convolution* tiga dimensi merupakan pengembangan dari *dilated convolution 2D* yang biasa digunakan pada CNN 2D. Dilated convolution 3D dapat memperbesar lebar spektrum tanpa mengubah parameter dan struktur asli model dengan konsumsi memori yang rendah, sedangkan *residual connection* digunakan untuk mengatasi permasalahan pada jaringan yang dalam.




Gambar 6. Arsitektur MSR [16]

Tabel 5. Detail Arsitektur MSR

Layer	Layer Type	Filter	Kernel	Dilation Rate	Fungsi Aktivasi
1	Input				
2	Conv_layer (Conv3D)	32	1, 1, 3	1, 1, 3	Relu
3	Conv_layer (Conv3D)	8	1, 1, 3	1, 1, 3	Relu
4	Conv_layer1 (Conv3D)	4	3, 3, 7	1, 1, 11	Relu
5	Conv_layer1_1 (Conv3D)	8	3, 3, 7	1, 1, 11	Relu
6	Conv_layer1_2 (Conv3D)	8	3, 3, 7	1, 1, 11	Relu
7	Conv_layer2 (Conv3D)	4	3, 3, 7	1, 1, 7	Relu
8	Conv_layer2_1 (Conv3D)	8	3, 3, 7	1, 1, 7	Relu
9	Conv_layer2_2 (Conv3D)	8	3, 3, 7	1, 1, 7	Relu
9	Conv_layer3 (Conv3D)	4	3, 3, 7	1, 1, 1	Relu
10	Conv_layer3_1 (Conv3D)	8	3, 3, 7	1, 1, 1	Relu
11	Conv_layer3_2 (Conv3D)	8	3, 3, 7	1, 1, 1	Relu
12	Merge Layer (ADD_layer)				

2.2.3 3D Spectral Dilated Convolution (SDC)

Pada umumnya, untuk mendapatkan bidang reseptif yang luas, dapat dilakukan dengan memperbesar ukuran kernel konvolusi secara langsung. Namun dengan teknik ini dapat menambah parameter model dan waktu pelatihan yang lebih lama. Salah satu alternatif untuk mengatasi permasalahan ini adalah penggunaan *dilated convolution*, yang dapat memperluas bidang reseptif tanpa meningkatkan ukuran model.



Gambar 7. Dilated Convolution 3 Dimensi [16]

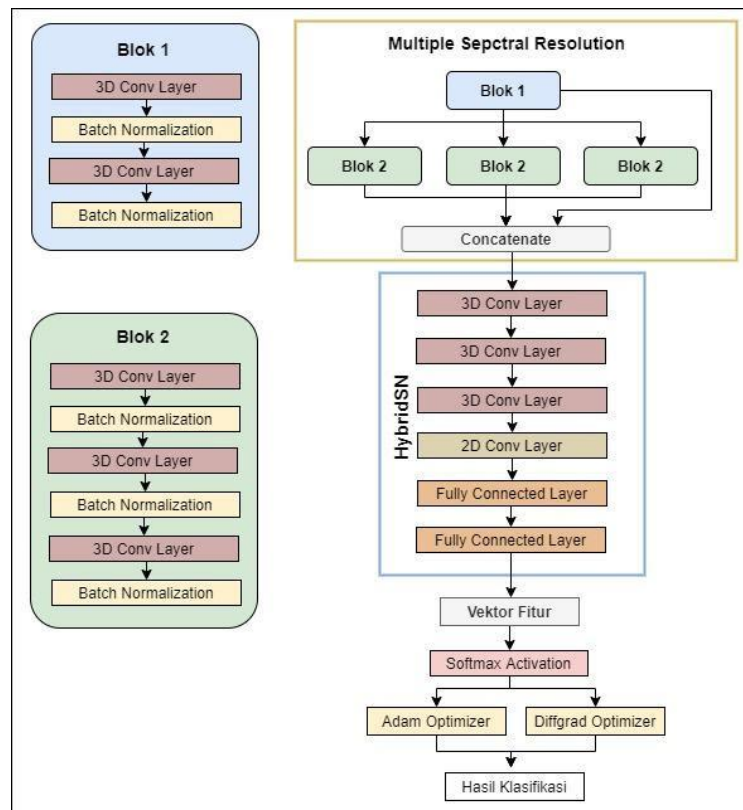


3D *Spectral Dilated Convolution* (SDC) yang diusulkan pada penelitian Xu dkk [16] merupakan adaptasi dari *dilated convolution* 2D. Metode SDC memperluas bidang reseptif kernel konvolusi di sepanjang dimensi spektral. Pada Gambar 7, balok hitam mewakili inti konvolusi dan balok garis merah menutupi bidang reseptif. Pada kernel 3x3x3, dilation rate yang diatur menjadi 1 sama dengan kernel konvolusi 3D biasa. Sedangkan untuk dilation rate yang diatur ke 2 dan 3 memiliki kedalaman spektral masing-masing bernilai 7 dan 11, yang berarti menjadikan ukuran kernel 3x3x7 dan 3x3x11.

2.2.4 Kombinasi Metode MSR dan HybridSN

Metode MSR terdiri dari 9 blok layer, dimana setiap blok memiliki 3 convolutional layer yang diikuti BatchNormalization setelahnya. Pada penelitian ini hanya digunakan 4 blok layer untuk mengurangi kompleksitas dan biaya komputasi model namun dengan kinerja yang optimal. Blok pertama merupakan satu-satunya blok yang memiliki dua conv.layer. Blok ini bertugas menerima input dari data yang sudah melalui tahap pra-proses. Kubus citra hiperspektral dipotong dalam ukuran yang lebih kecil sebagai patch menggunakan window size berukuran 15x15. Lalu data berupa patch 3D tersebut akan diekstraksi dengan conv.layer 3 dimensi.

Dapat dilihat pada Tabel 5, ukuran kernel penerima input diatur menjadi 1x1x3 dan dilation rate=3, hal ini disebabkan metode MSR menekankan pengolahan fitur spektral dengan meminimalisir ketergantungan akan fitur spasial. Dari blok pertama, patch data 3 dimensi akan diteruskan ke blok selanjutnya. Blok 2, 3 dan 4 berbentuk *multiscale spectral* dengan ukuran kedalaman spektral yang berbeda yaitu 3, 11 dan 7. Ketiga blok ini memproses data fitur dari conv.layer blok pertama, kemudian ketiga blok digabung dengan teknik Add() pada python seperti yang ditunjukkan pada Gambar 8 .



Gambar 8. Usulan Kombinasi MSR dan HybridSN

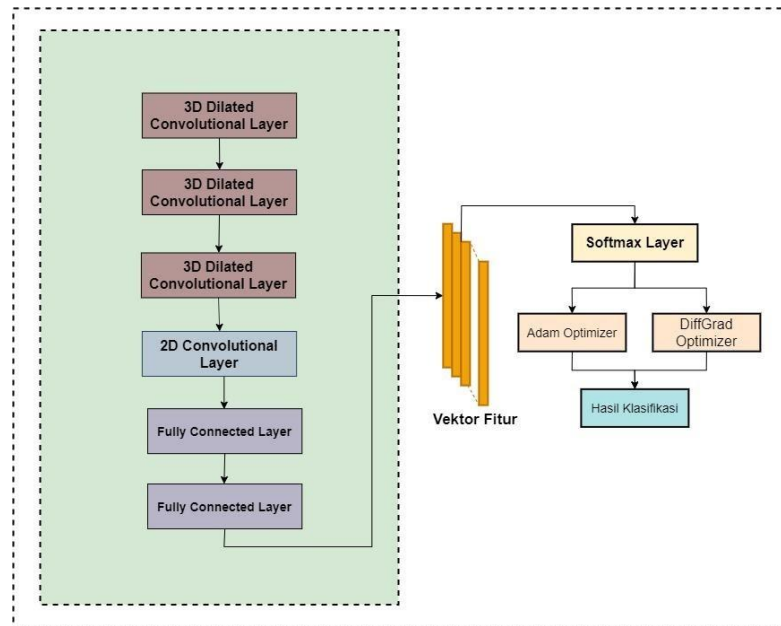
Tidak hanya menerima input dan meneruskan fitur ke blok berikutnya, blok pertama juga menjadi koneksi pintasan yaitu koneksi langsung antara input dan output blok atau biasa dikenal dengan *residual connection*, sehingga fitur dari blok pertama juga akan digabungkan dengan tiga blok lainnya pada layer Add. Gabungan fitur dari empat kedalaman spektral yang berbeda ini menjadi input dari arsitektur HybridSN yang terdiri dari tiga 3D conv.layer dan satu 2D conv.layer yang akan memproses kembali fitur yang dihasilkan metode MSR, diteruskan ke fully connected layer yang akan mengubah matriks menjadi vektor fitur untuk kemudian diklasifikasi.

2.2.6 Kombinasi Metode SDC dan HybridSN

3D *Spectral Dilated Convolution* (SDC) merupakan bagian dari metode MSR. Pada metode MSR, kerangka kerja difokuskan pada pemanfaatan fitur spektral dengan kernel input berukuran 1x1x3. Pada kombinasi SDC dan HybridSN, penulis akan menerapkan dilated convolution 3D pada kernel berukuran 3x3x7 yang memproses



fitur spektral spasial secara bersamaan. Berbeda dengan kombinasi MSR dan HybridSN, pada kombinasi SDC dan HybridSN patch 3D berukuran 15x15 menjadi input dan akan diekstrak oleh 3D convolutional layer dengan perluasan kedalaman spektrum yang tetap mempertahankan korelasi fitur spektral spasial. Kombinasi metode ini dioptimasi dengan Adam dan DiffGrad Optimizer. Gambar 9 menunjukkan implementasi dilated convolution (SDC) pada metode HybridSN.



Gambar 9. Usulan Kombinasi Metode SDC dan HybridSN

Selain dua arsitektur 3D CNN di atas yang ditunjukkan pada Tabel 4 dan Tabel 5, digunakan beberapa *hyperparameter* yang berfungsi mengoptimalkan kinerja CNN seperti *epoch*, optimisasi, *learning rate*, fungsi *loss* dan fungsi aktivasi *output layer* yang ditunjukkan pada Tabel 6.

Tabel 6. *Hyperparameter* CNN

No	Epoch	Optimisasi	Learning Rate	Fungsi Loss	Aktivasi Output Layer
1	10	Adam	0.001	Categorical Cross Entropy	Softmax
2	10	DiffGrad	0.999	Categorical Cross Entropy	Softmax

Dari penjelasan pada poin 2.2, kombinasi metode yang dilakukan dirangkum pada Tabel 7.

Tabel 7. Percobaan Kombinasi Metode

Model	Metode	Optimizer
1	HybridSN	Adam
2	HybridSN	DiffGrad
3	SDC + HybridSN	Adam
4	SDC + HybridSN	DiffGrad
5	MSR CNN + HybridSN	Adam
6	MSR CNN + HybridSN	DiffGrad

2.4 Evaluasi

Metode evaluasi yang digunakan pada penelitian ini adalah tiga teknik akurasi matriks pada klasifikasi penutup lahan secara umum, yaitu *Overall Accuracy* (OA), *kappa coefficient*, dan *Average Accuracy* (AA).

3. HASIL DAN PEMBAHASAN

Dalam penelitian ini digunakan dua dataset sekunder Indian Pines (IP) dan Salinas (SA) yang dipublikasikan oleh lembaga NASA dengan jumlah data masing-masing 10.249 dan 54.129 data. Sebelum melakukan klasifikasi, data citra terlebih dahulu dipraproses dengan teknik *oversampling*, reduksi dimensi dengan PCA dan



augmentasi data. Eksperimen pengujian dilakukan dengan mengkombinasikan metode MSR, HybridSN dan SDC dengan dua optimasi Adam dan Diffgrad yang menghasilkan 6 model pengujian berbeda. Pengujian dilakukan dengan menggunakan 95% data uji dan 5% sisanya sebagai data training.

3.1 Pengujian Pada Dataset Indian Pines (IP)

Dari 6 percobaan menggunakan kombinasi 6 model pada dataset IP, model ke 3 yang mengimplementasikan *dilated convolution* 3D (SDC) pada metode HybridSN menghasilkan akurasi tertinggi dengan OA sebesar 96,58%, AA 87,83% dan kappa 96,09%. Detail hasil akurasi ditunjukkan pada Tabel 5.

Tabel 5. Hasil akurasi 6 Model Pada Dataset IP

Model	Indian Pines (IP)		
	AA	OA	Kappa
1	81,80%	93,17%	92,18%
2	80,24%	94,69%	93,93%
3	87,83%	96,58%	96,09%
4	87,11%	95,92%	95,35%
5	82,84%	94,28%	93,47%
6	79,37%	93,27%	92,30%

Dari tabel 5 dapat dilihat akurasi tertinggi diperoleh model 3. Ini menunjukkan pengimplementasian 3D *dilated convolution* pada metode HybridSN tanpa menggunakan jaringan yang terlalu dalam lebih efektif dibandingkan menggunakan metode MSR (*dilated convolution* 3D multi skala dengan *residual connection*) dengan jaringan yang lebih deep (dalam) yang dikombinasikan dengan metode HybridSN dalam mengklasifikasi citra hiperspektral tutupan lahan. Optimasi Adam memiliki kinerja yang lebih baik dibanding optimasi DiffGrad. Dari 3 model, optimasi DiffGrad memiliki kinerja terbaik pada model ke 2 yang menggunakan arsitektur HybridSN standar. Pada kombinasi MSR-HybridSN dan SDC-HybridSN, metode optimasi Adam memiliki kinerja lebih baik.

3.2 Pengujian Pada Dataset Salinas (SA)

Dari 6 percobaan menggunakan kombinasi 6 model pada dataset SA, dengan data latih sebanyak 541 data dan data uji sebanyak 53588 data. Akurasi OA dan kappa tertinggi terjadi pada model 3 sedangkan akurasi AA tertinggi terjadi pada model 4. Detail hasil akurasi ditunjukkan pada Tabel 5.

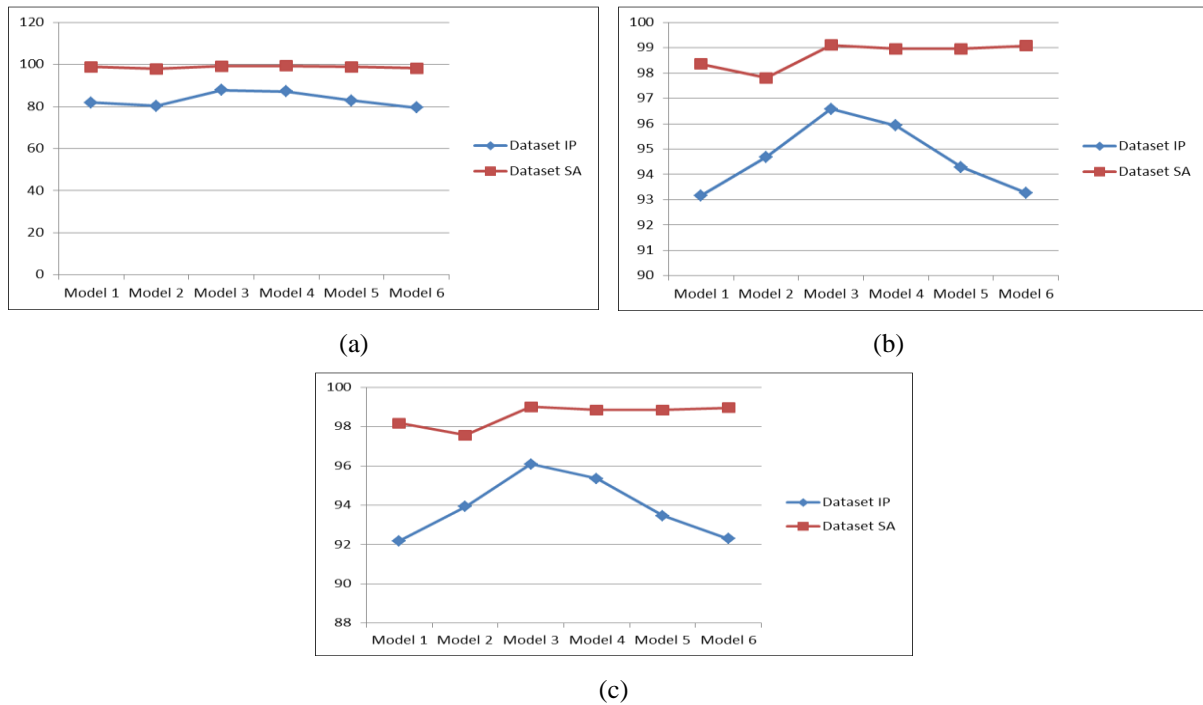
Tabel 6. Hasil akurasi 6 Model Pada Dataset SA

Model	Salinas (SA)		
	AA	OA	Kappa
1	98,80%	98,35%	98,17%
2	97,82%	97,81%	97,56%
3	99,08%	99,10%	99,00%
4	99,30%	98,95%	98,84%
5	98,79%	98,96%	98,85%
6	98,22%	99,07%	98,96%

Model 3 dan model 4 merupakan model dengan akurasi terbaik dari 6 model yang diuji. Model 3 memperoleh akurasi OA dan kappa tertinggi, sementara model 4 memperoleh akurasi AA tertinggi dari 5 model lainnya. Dari hasil yang diperoleh pada dataset SA, menunjukkan bahwa model tidak begitu terpengaruh pada keterbatasan sampel. Akan tetapi ketidakseimbangan data seperti yang terjadi pada dataset IP sangat mempengaruhi kinerja model. Pada dataset SA, hanya ada satu kelas yang memiliki 9 data latih, sedangkan pada dataset IP ada 3 kelas yang memiliki sampel pelatihan kurang dari 5 data. Sama seperti data IP, pada data SA kinerja model dengan jaringan yang dalam dengan 22 layer yang dimiliki metode MSR tidak lebih baik dibanding metode dengan jaringan lebih dangkal pada HybridSN yang dikombinasikan dengan metode SDC.

3.3 Perbandingan Kinerja Model Pada Dataset IP dan SA

Dari evaluasi pengujian 6 model pada dataset IP dan SA, model 1 dan model 2 memiliki akurasi rata-rata terendah. Model 1 merupakan HybridSN standar dengan optimasi Adam dan model 2 merupakan metode HybridSN standar yang dioptimasi dengan DiffGrad. Kinerja kedua model sudah cukup baik namun belum optimal. Akurasi tertinggi pada dua dataset diperoleh model 3 yang merupakan kombinasi metode SDC-HybridSN dengan optimasi Adam, dan model 4 yang merupakan kombinasi metode SDC-HybridSN dengan optimasi DiffGrad. Gambar 10 menunjukkan kurva perbandingan tiga jenis akurasi (AA, OA dan kappa) model 1 hingga model 6 pada dataset IP dan SA.



Gambar 10. Perbandingan Akurasi AA, OA dan Kappa Dari Masing-Masing Model Yang Diuji Pada Dataset IP dan SA

Pada gambar 10 (a) dapat dilihat performa 6 model pada dataset SA menghasilkan akurasi AA yang tinggi. Sedangkan pada gambar 10 (b) dan (c), model 2 mendapatkan akurasi OA dan kappa paling rendah. Model 3 dan 4 memiliki kinerja terbaik pada dua dataset, sementara model 5 dan 6 yang merupakan kombinasi metode MSR dan HybridSN yang masing-masing dioptimasi dengan Adam dan DiffGrad memiliki kinerja lebih rendah baik pada dataset IP maupun dataset SA. Hal ini disebabkan model 3 dan 4 menggunakan kernel yang lebih besar sehingga dapat memanfaatkan korelasi fitur spektral spasial, serta pengimplementasian *dilated convolution* 3D pada arsitektur HybridSN untuk mengeksplorasi fitur spektral spasial dari kubus hiperspektral 3 dimensi secara bersamaan dengan bidang reseptif yang lebih luas. Ini menunjukkan pada dataset tutupan lahan terutama pada data dengan set pelatihan yang sangat terbatas dan memiliki ketidakseimbangan data signifikan seperti pada dataset IP, penggunaan korelasi fitur spektral spasial masih lebih efektif dibanding mengeksplorasi salah satu fitur saja. Namun secara keseluruhan metode MSR yang lebih fokus pada informasi spektral sudah memiliki akurasi yang cukup tinggi meskipun dari pengujian yang dilakukan kinerjanya masih dibawah metode spektral spasial.

Metode optimasi DiffGrad memiliki kinerja dibawah optimasi Adam pada klasifikasi citra hiperspektral tutupan lahan dengan set pelatihan yang sangat terbatas. Dari total 6 uji coba pada dua data, optimasi DiffGrad memperoleh akurasi lebih baik dibanding Adam pada 3 eksperimen namun tidak pada semua jenis akurasi (AA, OA dan kappa).

Berdasarkan keseluruhan eskperimen pengujian, implementasi metode 3D *Spectral Dilated Convolution* (SDC) pada HybridSN dengan optimasi Adam memiliki kinerja paling stabil dan memperoleh akurasi tertinggi pada dua dataset. Dapat disimpulkan metode ekstraksi fitur spektral spasial dengan memanfaatkan pelebaran bidang reseptif spektral dan optimasi dengan Adam memiliki kinerja terbaik dari 5 model lain yang diuji pada citra hiperspektral tutupan lahan dengan jumlah data yang tidak seimbang dan sampel pelatihan yang sangat terbatas.

Tabel 7 dan Tabel 8 menunjukkan perbandingan kinerja metode yang diusulkan dengan 5 penelitian sebelumnya. Pada Tabel 7, pengujian dengan dataset IP menunjukkan kombinasi metode SDC dan HybridSN dengan optimasi Adam memperoleh akurasi tertinggi dibandingkan metode diverse region CNN, penggunaan tiga metode Group Intelligence (GI) (GA, PSO dan ABC) yang berbeda pada SVM, 3D DWF-CNN-MRF, multiscale 3D-2D CNN dan multiscale LSTM.

Tabel 7. Perbandingan Akurasi Dengan Penelitian Sebelumnya Pada Dataset IP

No	Metode	OA	AA	Kappa
1	CNN (Zhang dkk, 2018)	88,74%	-	-
2	SVM (Zhu dkk, 2019)	81,90%	-	-

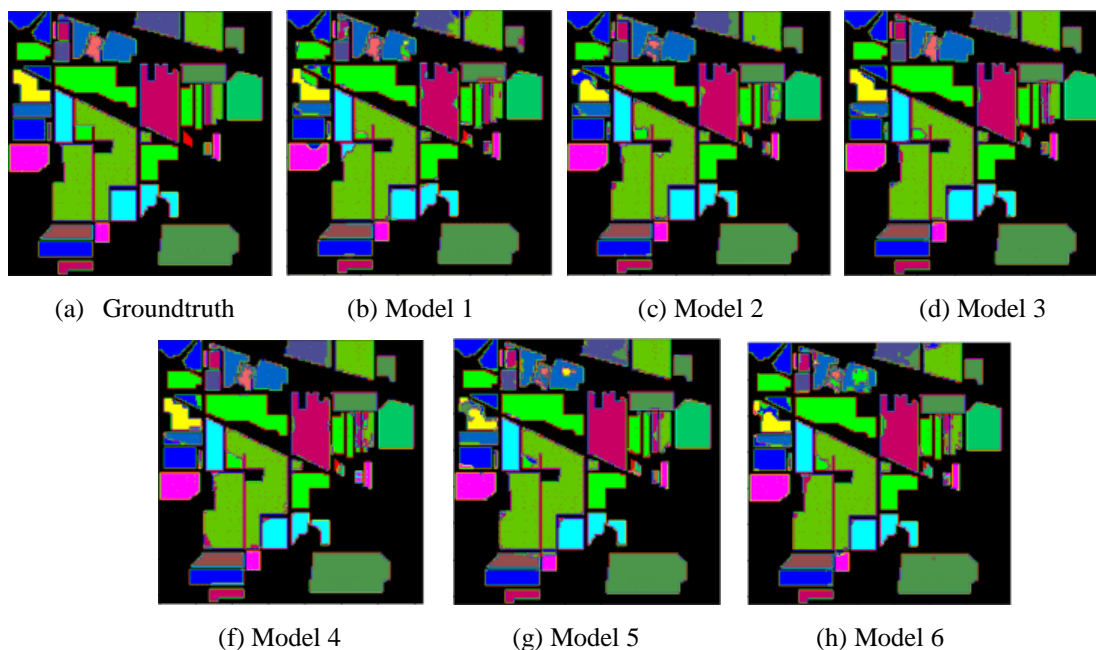


No	Metode	OA	AA	Kappa
3	3D discrete wavelete transform, CNN, MRF (Cao dkk, 2020)	91,98%	80,34%	-
4	CNN (Ge dkk, 2020)	96,07%	94,14%	95,51%
5	LSTM (Wang dkk, 2020)	88,25%	89,48%	86,50%
6	SDC-HybridSN-Adam Optimizer	96,58%	87,83%	96,09%

Tabel 8. Perbandingan Akurasi Dengan Penelitian Sebelumnya Pada Dataset SA

No	Metode	OA	AA	Kappa
1	CNN (Zhang dkk, 2018)	93,46%	-	-
2	SVM (Zhu dkk, 2019)	93,14%	-	-
3	3D discrete wavelete transform, CNN, MRF (Cao dkk, 2020)	-	-	-
4	CNN (Ge dkk, 2020)	-	-	-
5	LSTM (Wang dkk, 2020)	91,63%	94,58%	93,15%
6	SDC-HybridSN- Adam Optimizer	99,10%	99,08%	99,00%
7	SDC-HybridSN- DiffGrad Optimizer	99,30%	98,95%	98,84%

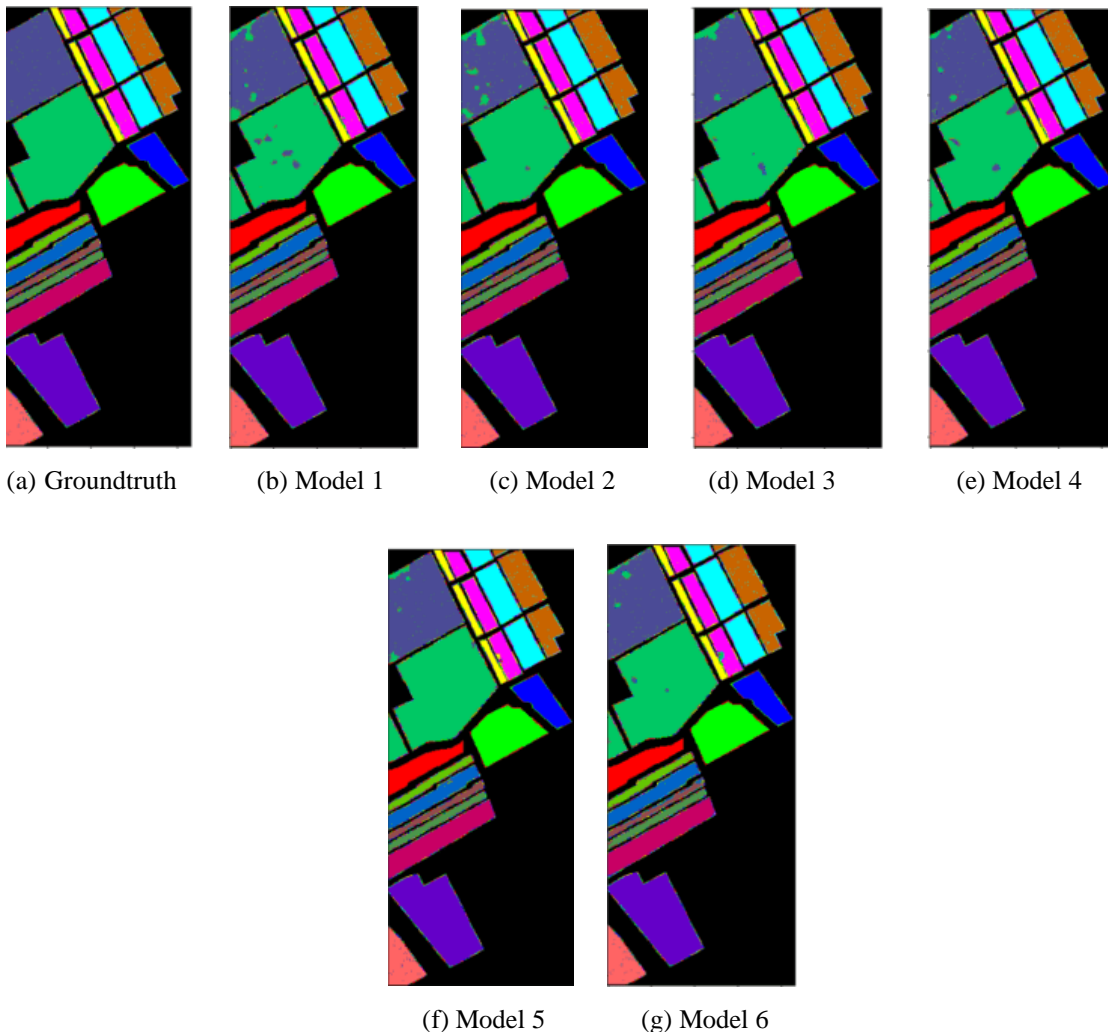
Tabel 8 juga menunjukkan hasil serupa, dimana pengujian pada dataset SA dengan perolehan akurasi tertinggi pada metode SDC HybridSN dengan Adam optimizer di dua akurasi AA dan kappa, sedangkan akurasi OA tertinggi diperoleh kombinasi metode SDC HybridSN yang dioptimasi dengan DiffGrad optimizer. Gambar 11 merupakan *groundtruth* dan peta hasil klasifikasi dataset IP. Gambar 11(a) terdapat *groundtruth* (peta kebenaran) yang digunakan sebagai rujukan untuk mengevaluasi model yang dikembangkan. Gambar 11(b) hingga 11(h) masing-masing merupakan peta hasil klasifikasi (*color map*) model 1 hingga model 6.



Gambar 11. Perbandingan *Groundtruth* dan Peta Hasil Klasifikasi Model 1 – Model 6 Pada Dataset IP

Dapat dilihat pada gambar terdapat perbedaan yang cukup signifikan, dimana ketika akurasi semakin tinggi maka tingkat kesamaan warna pada peta makin mendekati *groundtruth*. Sedangkan ketika akurasi rendah, maka warna yang dihasilkan pada peta hasil klasifikasi semakin berbeda dengan warna yang terdapat pada *groundtruth*.

Gambar 12 merupakan *groundtruth* dan peta hasil klasifikasi dari dataset Salinas (SA). Gambar 12(a) merupakan *groundtruth* dataset SA. Sedangkan gambar 12(b) hingga 12(g) adalah peta hasil klasifikasi dari enam model yang diuji pada dataset SA.



Gambar 12. Perbandingan *Groundtruth* dan Peta Hasil Klasifikasi Model 1 – Model 6 Pada Dataset SA

4. KESIMPULAN

Penelitian ini menggunakan kombinasi metode *Multiple Spectral Resolution* (MSR), *Hybrid Spectral Neural Network* (HybridSN) dan *3D Spectral Dilated Convolution* (SDC) dengan dua optimasi Adam dan DiffGrad. Dari pengujian terhadap 6 model, hasil terbaik diperoleh model 3 dengan akurasi OA 96,58%, AA 87,83% dan kappa 96,09% pada data IP sedangkan pada data SA, hasil OA dan kappa tertinggi diperoleh model 3 dengan akurasi sebesar 99,08% dan 99,00% dan akurasi AA tertinggi diperoleh model 4 sebesar 99,30%. Berdasarkan evaluasi kinerja model yang dilakukan, model 3 memiliki kinerja paling stabil pada dua dataset dibandingkan 5 model lainnya. Kombinasi metode SDC dan HybridSN tersebut terbukti dapat meningkatkan akurasi pada klasifikasi citra hiperspektral tutupan lahan dengan data pelatihan terbatas dan jumlah data yang tidak seimbang pada masing-masing kelas. Penggunaan jaringan yang *deep* (dalam) pada metode MSR tidak lebih baik dibanding SDC yang diterapkan pada jaringan yang lebih dangkal. Penggunaan fitur spektral spasial secara bersamaan pada kombinasi SDC dan HybridSN lebih cocok diterapkan pada citra hiperspektral tutupan lahan dengan data pelatihan terbatas dan data yang tidak seimbang dibanding menggunakan HybridSN saja maupun kombinasi MSR dan HybridSN.

REFERENCES

- [1] P. Helber, B. Bischke, A. Dengel, and D. Borth, "Eurosat: A novel dataset and deep learning benchmark for land use and land cover classification," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 12, no. 7, pp. 2217–2226, 2019, doi: 10.1109/JSTARS.2019.2918242.
- [2] X. Kang, S. Li, and J. A. Benediktsson, "HYPERSPETRAL IMAGE CLASSIFICATION: A BENCHMARK," pp. 2–5, 2017.
- [3] Sugianto and M. Rusdi, "PENGANTAR APLIKASI PENGINDERAAN JAUH HYPERSPECTRAL," p. 119, 2017.



- [4] A. Rangnekar, N. Mokashi, E. J. Ientilucci, C. Kanan, and M. J. Hoffman, "AeroRIT: A New Scene for Hyperspectral Image Analysis," *IEEE Transactions on Geoscience and Remote Sensing*, pp. 1–9, 2020, doi: 10.1109/tgrs.2020.2987199.
- [5] G. Krishna, R. N. Sahoo, S. Pradhan, T. Ahmad, and P. M. Sahoo, "Hyperspectral satellite data analysis for pure pixels extraction and evaluation of advanced classifier algorithms for LULC classification," *Earth Science Informatics*, vol. 11, no. 2, pp. 159–170, 2018, doi: 10.1007/s12145-017-0324-4.
- [6] J. Jia, Y. Wang, J. Chen, R. Guo, R. Shu, and J. Wang, "Status and application of advanced airborne hyperspectral imaging technology: A review," *Infrared Physics and Technology*, vol. 104, p. 103115, 2020, doi: 10.1016/j.infrared.2019.103115.
- [7] T. Postadjian, A. le Bris, H. Sahbi, and C. Mallet, "INVESTIGATING the POTENTIAL of DEEP NEURAL NETWORKS for LARGE-SCALE CLASSIFICATION of VERY HIGH RESOLUTION SATELLITE IMAGES," *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 4, no. 1W1, pp. 183–190, 2017, doi: 10.5194/isprs-annals-IV-1-W1-183-2017.
- [8] R. Nijhawan, J. Das, and R. Balasubramanian, "A Hybrid CNN + Random Forest Approach to Delineate Debris Covered Glaciers Using Deep Features," *Journal of the Indian Society of Remote Sensing*, vol. 46, no. 6, pp. 981–989, 2018, doi: 10.1007/s12524-018-0750-x.
- [9] J. Liang, J. Zhou, Y. Qian, L. Wen, X. Bai, and Y. Gao, "On the Sampling Strategy for Evaluation of Spectral-Spatial Methods in Hyperspectral Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 2, pp. 862–880, 2016, doi: 10.1109/TGRS.2016.2616489.
- [10] M. Zhang, W. Li, and Q. Du, "Diverse region-based CNN for hyperspectral image classification," *IEEE Transactions on Image Processing*, vol. 27, no. 6, pp. 2623–2634, Jun. 2018, doi: 10.1109/TIP.2018.2809606.
- [11] X. Zhu, N. Li, and Y. Pan, "Optimization performance comparison of three different group intelligence algorithms on a SVM for hyperspectral imagery classification," *Remote Sensing*, vol. 11, no. 6, 2019, doi: 10.3390/RS11060734.
- [12] X. Cao, J. Yao, X. Fu, H. Bi, and D. Hong, "An Enhanced 3-D Discrete Wavelet Transform for Hyperspectral Image Classification," *IEEE Geoscience and Remote Sensing Letters*, vol. 18, no. 6, pp. 1104–1108, 2020, doi: 10.1109/lgrs.2020.2990407.
- [13] Z. Wang, C. Zou, and W. Cai, "Small sample classification of hyperspectral remote sensing images based on sequential joint deeping learning model," *IEEE Access*, vol. 8, pp. 71353–71363, 2020, doi: 10.1109/ACCESS.2020.2986267.
- [14] Z. Ge, G. Cao, and P. Fu, "Hyperspectral Image Classification Method Based on 2D–3D CNN and Multibranch Feature Fusion," *Laser and Optoelectronics Progress*, vol. 57, no. 20, pp. 5776–5788, 2020, doi: 10.3788/LOP57.202803.
- [15] S. K. Roy, G. Krishna, S. R. Dubey, and B. B. Chaudhuri, "HybridSN: Exploring 3-D-2-D CNN Feature Hierarchy for Hyperspectral Image Classification," *IEEE Geoscience and Remote Sensing Letters*, vol. 17, no. 2, pp. 277–281, 2020, doi: 10.1109/LGRS.2019.2918719.
- [16] H. Xu, W. Yao, L. Cheng, and B. Li, "Multiple spectral resolution 3D convolutional neural network for hyperspectral image classification," *Remote Sensing*, vol. 13, no. 7, 2021, doi: 10.3390/rs13071248.
- [17] X. Cao, C. Wei, J. Han, and L. Jiao, "Hyperspectral Band Selection Using Improved Classification Map."
- [18] J. H. Oh, J. Y. Hong, and J. G. Baek, "Oversampling method using outlier detectable generative adversarial network," *Expert Systems with Applications*, vol. 133, pp. 1–8, Nov. 2019, doi: 10.1016/j.eswa.2019.05.006.
- [19] L. Zhou, W. Ma, H. Zhang, L. Li, and L. Tang, "Developing a PCA–ANN model for predicting chlorophyll a concentration from field hyperspectral measurements in dianshan lake, China," *Exposure and Health*, vol. 7, no. 4, pp. 591–602, Dec. 2015, doi: 10.1007/s12403-015-0175-5.
- [20] W. Li, C. Chen, M. Zhang, H. Li, and Q. Du, "Data Augmentation for Hyperspectral Image classification with deep cnn," *IEEE Geosciences And Remote Sensing Letters*, 2018.