

## Perbandingan Algoritma Klasifikasi untuk Mendeteksi Kebutuhan Nitrogen Tanaman Padi Berdasarkan Data Citra *Multi-spectral Drone*

### *Comparison of Classification Algorithms for Detecting Nitrogen Needs in Rice Plants Based on Multi-spectral Drone Images*

KAHFI GUNARDI<sup>1</sup>, KARLISA PRIANDANA\*<sup>1</sup>, MEDRIA KUSUMA DEWI  
HARDHIENATA<sup>1</sup>, WULANDARI, MOHAMAD SOLAHUDIN<sup>1</sup>

#### Abstrak

Optimalisasi penggunaan pupuk nitrogen (N) menjadi hal yang krusial dalam upaya meningkatkan produktivitas tanaman padi. Penentuan jumlah pupuk yang tepat untuk tanaman padi sering kali dilakukan dengan bagan bagan warna daun (BWD), di mana petani secara manual mencocokkan warna daun padi dengan skala warna pada BWD namun, proses ini terbukti memakan waktu. Salah satu strategi untuk meningkatkan efisiensi penentuan kebutuhan pupuk N adalah dengan menggunakan *multi-spectral drone*. Drone digunakan untuk mengambil citra multispectral, yang selanjutnya digunakan untuk menentukan kebutuhan pupuk N. Penelitian ini bertujuan membandingkan beberapa algoritma klasifikasi untuk memodelkan kebutuhan pupuk N dari data citra multispectral, dengan menggunakan *ground truth* dari penskalaan BWD. Algoritma klasifikasi yang diuji antara lain *decision tree* (DT), *artificial neural network* (ANN), *support vector machine* (SVM), *random forest* (RF), dan *k-nearest neighbour* (KNN). Kinerja kelima algoritma klasifikasi dievaluasi berdasarkan metrik *accuracy*, *recall*, *precision* dan *F1 score*. Hasil penelitian menunjukkan bahwa model klasifikasi yang memberikan kinerja terbaik adalah algoritma *decision tree* (DT) baik dalam perlakuan tanpa normalisasi dan *balancing*, maupun normalisasi dan *balancing* dengan nilai *accuracy*, *recall*, *precision*, dan *F1-score* di atas 90%.

Kata Kunci: algoritma klasifikasi, bagan warna daun, *drone* multi-spektral, padi.

#### Abstract

*Optimizing the use of nitrogen (N) fertilizer is very important for increasing the productivity of rice plants. Traditionally, determining the appropriate fertilizer amount involves employing a leaf color chart (BWD), where farmers manually match rice leaf colors to a color scale. However, this method proves time-consuming. A promising strategy to boost efficiency involves utilizing a Multi-spectral Drone to capture multispectral images for precise N fertilizer assessment. This study aims to compare various classification algorithms for modeling N fertilizer needs from multispectral image data, using ground truth from BWD scaling. The classification algorithms tested include decision tree (DT), artificial neural network (ANN), support vector machine (SVM), random forest (RF), and k-nearest neighbor (KNN). The performance of the five classification algorithms is evaluated based on the metrics of accuracy, recall, precision, and F1 score. The results show that the classification model that provides the best performance is the decision tree (DT) algorithm, both in treatment without normalization and balancing, as well as in treatment involving normalization and balancing with accuracy, recall, precision, and F1-score values above 90%.*

*Keywords: classification algorithm, leaf color chart, multi-spectral drone, rice plant.*

<sup>1</sup> Departemen Ilmu Komputer, FMIPA, Institut Pertanian Bogor, Bogor 16680;

\* Penulis Korespondensi: [karlisa@apps.ipb.ac.id](mailto:karlisa@apps.ipb.ac.id)

## PENDAHULUAN

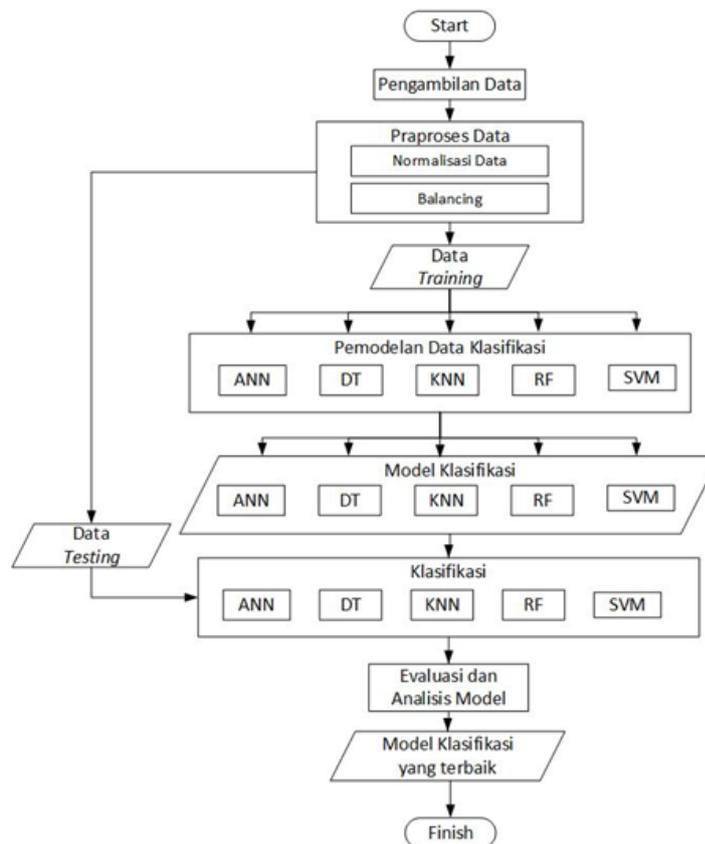
Pertanian presisi merupakan sistem pertanian terpadu berbasis pada informasi dan produksi guna meningkatkan efisiensi, produktivitas, dan profitabilitas dalam sektor pertanian (Sondakh *et al.* 2020). Dalam konteks pertanian presisi, petaan kesuburan lahan menjadi krusial sebagai pedoman dalam pemupukan. Untuk pertanian padi, petaan kesuburan lahan sering kali menggunakan bagan warna daun (BWD) sebagai indikator kebutuhan pupuk nitrogen (N) pada tanaman padi (Litbang Pertanian 2020). Tantangannya terletak pada penggunaan BWD oleh petani yang sering hanya dilakukan dengan cara mengambil sampel dari satu atau beberapa tanaman saja. Padahal, untuk menciptakan petaan kesuburan lahan pertanian padi yang presisi, diperlukan jumlah data yang memadai untuk dapat merepresentasikan kebutuhan N pada tanaman padi. Teknologi menjadi krusial dalam membantu mengukur kebutuhan N berdasarkan BWD secara efektif dan menyeluruh.

Pada penelitian sebelumnya, teknologi penggunaan penginderaan jarak jauh berbasis *unmanned aerial vehicle* (UAV) atau *drone* telah diterapkan untuk pemantauan tanaman padi (Hashimoto *et al.* 2019). UAV adalah teknologi kendaraan udara tidak berawak yang digunakan dalam penginderaan jarak jauh untuk mengumpulkan data citra pantulan spektral yang menjadi sumber informasi penting dalam menentukan kandungan nitrogen (Zha *et al.* 2020). Citra multi-spectral yang didapat dari penginderaan jarak jauh menggunakan UAV mampu memprediksi kandungan nitrogen (N) dalam tanaman padi (Zha *et al.* 2020). Berbagai metode klasifikasi telah diterapkan untuk memprediksi kandungan nitrogen pada tanaman padi yang didapat dari citra *multispectral*. Penelitian Zha *et al.* (2020) menggunakan tiga metode *machine learning* yaitu *random forest* (RF), *support vector machine* (SVM), dan *artificial neural networks* (ANN) dalam klasifikasinya. Dalam penelitian tersebut, RF secara signifikan mampu meningkatkan prediksi kandungan N pada penginderaan jarak jauh UAV. Pada penelitian Tipones dan Cruz (2019), SVM menghasilkan akurasi 96.2% pada *training set* dan 83.5% pada *testing set*. Islam *et al.* (2020) menerapkan metode *decision tree* (DT) dan menghasilkan akurasi 91.22% untuk mengklasifikasikan data citra. Ahmed K *et al.* (2019) juga mengimplementasikan metode *machine learning* yaitu *k-nearest neighbour* (KNN), DT, dan *naïve bayes* untuk klasifikasi penyakit pada daun padi berdasarkan data citra. Hasil Penelitian menunjukkan bahwa KNN mencapai akurasi 98.8 % untuk *training set* dan DT mendapatkan akurasi 97.9% untuk *testing set*. Melalui serangkaian penelitian tersebut, metode klasifikasi dapat digunakan untuk memantau kandungan nitrogen pada tanaman.

Pada penelitian ini melakukan pengambilan data citra *multispectral* menggunakan *drone* sehingga diharapkan dapat dilakukan pemantauan kadar nitrogen secara *real-time*. Data citra lahan sawah akan diambil di Margajaya Kecamatan Dramaga, Kabupaten Bogor. Untuk mengatasi kendala kemungkinan adanya *imbalanced data*, teknik SMOTE akan diterapkan. Selain itu, hasil klasifikasi terhadap data yang dinormalisasi dan tidak dinormalisasi akan dibandingkan untuk melihat kualitas data yang didapatkan. Kinerja dari lima algoritma klasifikasi yaitu ANN, DT, KNN, RF, dan SVM akan dibandingkan untuk menentukan model klasifikasi terbaik untuk memprediksi kebutuhan nitrogen pada tanaman padi menggunakan citra *multispectral* yang didapatkan dari *drone* berdasarkan BWD.

## METODE

Gambar 1 menunjukkan tahapan penelitian yang dimulai dengan tahap pengambilan data, tahap praproses, pengembangan model, dan evaluasi model. Normalisasi data dan *balancing* data akan dilakukan pada tahap praproses data. Selanjutnya, data tersebut dibagi 80% untuk *training* dan 20% untuk *testing*. Data *training* digunakan untuk pembangunan model dengan beberapa teknik klasifikasi yaitu ANN, DT, KNN, RF, dan SVM. Selanjutnya, data *testing* akan digunakan untuk mengevaluasi hasil model yang dikembangkan.



Gambar 1 Tahapan penelitian

## Pengambilan Data

Proses pengambilan data ditunjukkan pada Gambar 2 hingga Gambar 8. Pengambilan data citra menggunakan kamera *multispectral* yang diterapkan pada *drone* ditunjukkan oleh Gambar 2. Lokasi pengambilan data lahan sawah berada di Margajaya Kecamatan Dramaga, Kabupaten Bogor. Citra diambil dengan ketinggian 50 meter dari permukaan tanah. Spektrum citra yang digunakan yaitu 550 nm, 660 nm, 735 nm, dan 790 nm. Citra yang didapatkan berupa citra RGB, NIR, *red-edge*, *red*, dan *green channel*. Hasil citra kemudian diberikan *grid* 4 x 4 m menggunakan aplikasi ArcGIS hasilnya seperti ditunjukkan oleh Gambar 3. Pemilihan ukuran *grid* berukuran 4 m x 4 m berdasarkan pada penelitian yang dilakukan oleh Astika *et al.* (2011). Pada penelitian ini dilakukan pelabelan pada masing-masing *grid* (Gambar 4) berdasarkan warna daun yang merujuk pada bagan warna daun (BWD) (Gambar 5). Pelabelan tersebut dilakukan dengan melihat warna hijau daun paling dominan di dalam *grid* tersebut. Setiap bagan pada BWD mewakili takaran pupuk yang perlu diberikan oleh petani berdasarkan warna daun. Gambar 6 menunjukkan hasil dari pelabelan pada setiap *grid*. Selanjutnya, nilai dari masing-masing *channel* untuk setiap *grid* pada citra sawah tersebut diekstrak menggunakan *library* OpenCV dan bahasa pemrograman Python 3.8. Proses ekstraksi dalam setiap *grid* dilakukan sebagai berikut:

1. Mengetahui jumlah *pixel* pada panjang dan lebar setiap *grid*  
Jumlah *pixel* didalam 1 *grid* berbentuk kotak diketahui dengan cara membagi total *pixel* panjang citra dengan jumlah *grid* pada panjang citra dan membagi total *pixel* lebar citra dengan jumlah *grid* pada lebar citra.
2. Melakukan ekstraksi nilai rata-rata *pixel*  
Nilai *pixel* untuk setiap *grid* diambil berdasarkan nilai rata-rata seluruh *pixel* pada *grid* dari masing-masing *channel* yang diekstraksi. Sampel hasil akhir pengambilan data dapat dilihat pada Gambar 7.



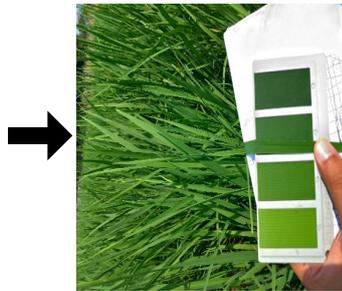
Gambar 2 Citra *multi-spectral drone*



Gambar 3 Pemberian *grid*



Gambar 4 Sampel lahan sawah



Gambar 5 Pengukuran dengan BWD



Gambar 6 Label lahan sawah

No	rgb_b1	rgb_b2	rgb_b3	green_b1	green_b2	ndvi_b1	nir_b1	nir_b2	red_b1	red_b2	redEdge_b1	redEdge_b2	Label
1	160,5325952	157,176609	141,5133564	16915,38035	252,5411765	9,475441	30633,82671	252,5411765	8828,740346	252,5411765	29784,55087	252,5411765	4
2	132,5789619	134,9595848	112,5283045	14099,60803	252,5107266	9,537767	22463,84872	252,5107266	8229,619792	252,5107266	22394,01578	252,5107266	3
3	116,2687889	118,3140484	87,00955017	14130,49356	252,5107266	9,37549	18453,53965	252,5107266	9323,623391	252,5107266	19167,00595	252,5107266	3
4	105,0047059	106,0350173	94,60678201	17346,1164	252,5107266	9,422446	23115,77467	252,5107266	11053,04152	252,5107266	24694,17121	252,5107266	3
5	137,1986159	130,7341176	117,2838754	17396,17619	252,5107266	9,442769	23190,69813	252,5107266	11511,81993	252,5107266	24804,6263	252,5107266	3
6	149,7929412	143,3804844	122,4555017	20599,71183	252,5107266	9,389227	23523,80471	252,5107266	15294,95848	252,5107266	26214,76512	252,5107266	3
7	146,387128	139,8815225	117,5572318	22570,63308	252,5107266	9,132314	20623,29398	252,5107266	18685,58173	252,5107266	24279,91322	252,5107266	3
8	138,3712111	132,963045	113,2808304	15032,08443	252,5107266	9,094431	13833,72609	252,5107266	12932,20997	252,5107266	15184,88761	252,5107266	3
9	158,1530796	155,3570934	141,7417301	14676,10547	252,5107266	9,46266	21633,87917	252,5107266	9536,852042	252,5107266	21646,40249	252,5107266	3
10	148,982699	150,0058131	130,2052595	13187,6728	252,5107266	9,348557	15954,71626	252,5107266	9181,153218	252,5107266	15675,03308	252,5107266	3
11	139,2395848	138,313218	119,6469204	14179,91253	252,5107266	9,319834	15106,64872	252,5107266	10040,4537	252,5107266	16129,51045	252,5107266	3
12	128,5836678	127,8152249	112,499654	15947,24346	252,4574394	9,535492	17473,44471	252,4574394	11315,16997	252,4574394	19091,9791	252,4574394	2
13	147,2476125	141,8168858	123,0029066	15891,99875	252,4574394	9,611381	18678,92581	252,4574394	10972,4836	252,4574394	20294,47765	252,4574394	2
14	149,8607612	144,2322491	122,4334948	15839,30644	252,4574394	9,694061	23516,94367	252,4574394	10758,52304	252,4574394	24861,44457	252,4574394	2
15	142,5822837	138,4131488	112,9439446	21161,30256	252,4574394	9,366588	19210,75779	252,4574394	17544,91197	252,4574394	22099,12152	252,4574394	2

Gambar 7 Sampel hasil akhir pengambilan data

### Ekstraksi Data

Ekstraksi data dilakukan dengan menjadikan nilai rata-rata channel gelombang pada setiap *grid* sebagai fitur dan hasil pelabelan berdasarkan warna daun yang merujuk pada BWD. Berikut kanal gelombang cahaya yang didapat dari sensor *multispectral* (CIFOR 2019):

1. Band 1 kanal biru  
Kanal gelombang ini digunakan untuk pencitraan gambar yang ada di atmosfer dan bawah air dengan tingkat kedalaman hingga 50 meter. Band 1 kanal biru dalam penelitian diperoleh tiga fitur sehingga diberikan label dengan nama *rgb\_b1*, *rgb\_b2* dan *rgb\_b3*
2. Band 2 kanal hijau  
Kanal gelombang ini digunakan untuk pencitraan gambar agrikultural dan struktur bawah air dengan kedalaman hingga 30 meter. Band 2 kanal hijau dalam penelitian diperoleh dua fitur sehingga diberikan label dengan nama *green\_b1* dan *green\_b2*
3. Band 3 kanal merah  
Kanal gelombang ini digunakan untuk pencitraan benda-benda buatan manusia, objek di bawah air dengan kedalaman 9 m, pertambangan, dan agrikultural. Band 3 kanal merah dalam penelitian diperoleh dua fitur sehingga diberikan label dengan nama *red\_b1* dan *red\_b2*
4. Band 4 kanal *near infrared radiation* (NIR)  
Kanal gelombang ini digunakan untuk kebutuhan agrikultural. Band 4 kanal NIR dalam penelitian diperoleh dua fitur sehingga diberikan label dengan nama *nir\_b1* dan *nir\_b2*

### 5. *Normalized difference vegetation index (NDVI)*

Indeks vegetasi atau NDVI adalah indeks yang menggambarkan tingkat kehijauan suatu tanaman. Indeks vegetasi merupakan kombinasi matematis antara band merah dan band NIR yang digunakan sebagai indikator keberadaan dan kondisi vegetasi. Perhitungan nilai NDVI ditunjukkan oleh Persamaan 1.

$$NDVI = (NIR - Red) / (NIR + Red) \quad (1)$$

NIR= radiasi inframerah dekat dari piksel      Red= radiasi cahaya merah dari piksel

### 6. Kanal *RedEdge*

Kanal gelombang ini digunakan untuk kebutuhan agrikultural. Band kanal *RedEdge* dalam penelitian diperoleh dua fitur sehingga diberikan label dengan nama *RedEdge\_b1* dan *RedEdge\_b2*.

## Praproses Data

Data yang dihasilkan pada tahap pengambilan data dapat dilihat pada Tabel 1 yang memberikan gambaran umum tentang dataset. Tabel 1 menampilkan nilai rata-rata dari setiap kolom dataset merupakan kanal gelombang dari setiap *grid*, dengan total 544 entri data dan tipe data *float*. Selain itu, Tabel 1 juga menunjukkan terdapat perbedaan skala nilai antar fitur. Oleh karena itu, dilakukan proses normalisasi data menggunakan metode *Z-score*. Perhitungan metode *Z-score* diperlihatkan dalam Persamaan 2.

$$r = (x - \mu) / \sigma \quad (2)$$

$x$  = nilai dari setiap titik data

$\mu$  = rata-rata dari seluruh titik data dalam distribusi

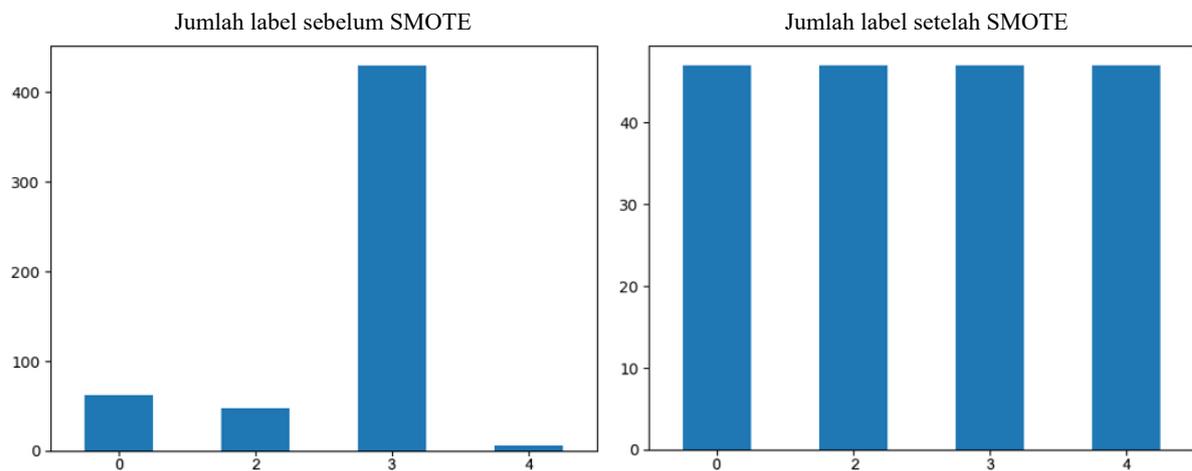
$\sigma$  = standar deviasi dari seluruh titik data dalam distribusi

Metode ini membantu dalam normalisasi data dengan mengurangi perbedaan skala antara variabel-variabel yang berbeda (Kreyszig *et al.* 2010). Metode ini dipilih karena metode *Z-score* mempertahankan distribusi asli data dengan menggunakan rata-rata dan simpangan baku (*standard deviation*) untuk menormalkan datanya sehingga informasi yang signifikan pada mayoritas data tidak hilang. Hasilnya skala perbedaan setiap nilai fitur tidak jauh berbeda.

Tabel 1 Overview praproses data

No	Kolom	Jumlah Baris	Tipe	Skala Nilai Awal	Skala Nilai Setelah Normalisasi
1	rgb_b1	544	float	105 – 109	-4 – 3
2	rgb_b2	544	float	106 – 177	-4 – 3
3	rgb_b3	544	float	87 – 167	-4 – 3
4	green_b1	544	float	131 – 493	0 – 9
5	green_b2	544	float	132 – 252	-3 – 0
6	ndvi	544	float	9 – 12	-1 – 0
7	nir_b1	544	float	13796 - 40377	-2 – 3
8	nir_b2	544	float	252 – 253	-1 – 2
9	red_b1	544	float	8200 - 14000	-1 – 8
10	red_b2	544	float	252 – 253	-1 – 2
11	redEdge_b1	544	float	13700 – 39400	-2 – 3
12	redEdge_b2	544	float	252 – 253	-3

Karakteristik label dataset dapat dilihat pada Gambar 8. Pada sumbu-x Gambar 8 terdapat jenis label, sementara sumbu-y menunjukkan jumlah data untuk setiap label. Gambar 8 juga mengindikasikan ketidakseimbangan data (*imbalance data*) pada dataset. Jumlah data dengan label 3 berjumlah lebih dari 400, label 2 kurang dari 100, label 3 kurang dari 50, dan label 4 berjumlah kurang dari 10.



Gambar 8 Diagram perbandingan jumlah label dataset

Oleh karena itu, dilakukan metode *balancing* dengan metode *synthetic minority oversampling* (SMOTE). SMOTE adalah metode *oversampling* yang digunakan untuk menangani data yang tidak seimbang (*imbalanced data*) dengan strategi interpolasi (Chawla *et al.* 2002). SMOTE menciptakan sampel sintesis dengan menghitung perbedaan atribut antara contoh dan tetangganya, kemudian dikalikan dengan bilangan acak antara 0 dan 1 pada ruang atribut. Hasil dari *balancing* menggunakan SMOTE menunjukkan jumlah label data pada dataset menjadi seimbang atau sama banyak.

### Teknik Klasifikasi

Klasifikasi dilakukan menggunakan lima algoritma klasifikasi, yaitu:

#### 1. *Artificial neural network* (ANN)

*Artificial neural network* adalah suatu jaringan yang memodelkan sistem saraf otak manusia (yang disebut neuron) dalam melaksanakan tugas pengenalan pola, khususnya klasifikasi (Simon 1999). Proses pembelajaran pada ANN dilakukan melalui beberapa tahap, yaitu:

- *Feedforward*: data masukan diteruskan dari lapisan input melalui lapisan tersembunyi ke lapisan *output*. Pada setiap neuron, nilai masukan dijumlahkan dengan bobot (*weight*) dan biasanya, kemudian hasilnya diaktivasi menggunakan fungsi aktivasi dengan persamaan 3.

$$\varphi(\cdot) = \begin{cases} 1 & \text{if } \sum_{i=0}^n w_i * x_i \geq 0 \\ 0 & \text{if } \sum_{i=0}^n w_i * x_i < 0 \end{cases} \quad (3)$$

dengan

$\varphi(\cdot)$  = *activation function*  
 n = jumlah *input signal*  
 w = bobot  
 x = *input*

- *Backpropagation*: hasil *output* dibandingkan dengan target yang sebenarnya (*ground truth*). Kemudian, kesalahan (*error*) antara *output* dan target digunakan untuk mengoptimalkan bobot dan bias pada setiap *neuron*.
- Optimasi dan iterasi: proses *feedforward* dan *backpropagation* dilakukan secara berulang-ulang (iterasi) untuk mengurangi kesalahan dan meningkatkan performa model.

Parameter dari algoritma ANN adalah ukuran *hidden layer* (*hidden\_layer\_sizes*), algoritma optimasi (*solver*), fungsi aktivasi (*activation*), *learning rate* (*learning\_rate*), dan maksimal iterasi (*max\_iter*).

## 2. Decision tree (DT)

*Decision tree* merupakan salah satu *predictive* model yang menggunakan struktur mirip pohon (*flowchart*) dengan membagi (*split*) data berulang kali sehingga membentuk pohon keputusan biner (*binary tree*) (Quinlan 1986). Proses pembelajaran pada DT dilakukan melalui beberapa tahap, yaitu:

- Persiapan data: langkah awal adalah mempersiapkan data pelatihan yang terdiri dari fitur-fitur (*features*) dan label atau target yang ingin diprediksi.
- Pemilihan fitur terbaik: algoritma DT memilih fitur yang paling informatif atau yang paling baik dalam membagi data berdasarkan metrik *entropy* dengan Persamaan 4.

$$Entropy(s) = -\sum_{i=1}^N P_i \log_2 P_i, \quad (4)$$

dengan

$P_i$  = probabilitas dari sampel ke- $i$

$N$  = jumlah total sampel

$S$  = *entropy*

- Pembagian data: data pelatihan dibagi berdasarkan fitur terbaik yang telah dipilih, membentuk cabang atau *node* baru dalam pohon.
- Rekursi: proses pemilihan fitur dan pembagian data diulang untuk setiap cabang atau *node* baru hingga kriteria berhenti terpenuhi.
- Kriteria berhenti: proses rekursi berhenti jika salah satu kriteria berhenti terpenuhi, misalnya ketika jumlah sampel di *node* mencapai batas minimum atau *impurity*.
- Label kelas: setelah pohon keputusan selesai dibangun, label kelas ditetapkan untuk setiap daun (*leaf*) berdasarkan mayoritas kelas data pelatihan di daun tersebut.
- *Pruning* (pemangkasan): opsional, pemangkasan dapat dilakukan untuk menghapus cabang atau *node* yang tidak signifikan untuk mencegah *overfitting* dan meningkatkan generalisasi pada data uji.

Parameter dari algoritma DT adalah kriteria pemisahan (*criterion*), jumlah sampel minimum *split* (*min\_samples\_split*), jumlah sampel minimum *leaf* (*min\_samples\_leaf*), jumlah fitur maksimum (*max\_features*), penyeimbang kehadiran kelas (*class\_weight*) dan *random state*.

## 3. K-nearest neighbour (KNN)

*K-nearest neighbour* merupakan metode yang bekerja dengan cara mencari sejumlah  $k$  objek data atau pola (dari semua pola latih yang ada) yang paling dekat dengan pola masukan, kemudian memilih kelas dengan jumlah pola terbanyak di antara  $k$  pola tersebut (Shakhnarovich *et al.* 2015). Proses pembelajaran pada KNN dilakukan melalui beberapa tahap, yaitu:

- Menentukan nilai  $k$
- Menghitung jarak antara data uji dengan setiap data latih menggunakan rumus *Euclidean distance* dengan Persamaan 5.

$$d(q_i, p_i) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2}, \quad (5)$$

dengan

$d$  = jarak *Euclidean* antara data uji dengan setiap data latih

$n$  = jumlah data

$q_i$  = nilai data uji

$p_i$  = nilai data latih

- Mendapatkan  $k$  data yang memiliki jarak terdekat
- Dari  $k$  data yang memiliki jarak terdekat, diperoleh kelas yang paling banyak muncul
- Kelas yang paling banyak muncul ditentukan sebagai kelas dari data uji.

Parameter dari algoritma KNN adalah  $n\_neighbors$ ,  $weights$  dan metrik yang digunakan.

#### 4. *Random forest* (RF)

*Random forest* merupakan kombinasi pohon keputusan yang setiap pohon bergantung pada nilai-nilai vektor acak yang disampling secara independen dengan distribusi yang sama (Suyanto 2021). *Random forest* terdiri dari empat tahapan (Sartono *et al.* 2010) sebagai berikut:

- Pemilihan sampel acak menggunakan *bootstrap* (pengambilan dengan penggantian).
- Pembentukan pohon keputusan atau *decision tree*: membangun banyak pohon keputusan (*decision tree*) dengan menggunakan dataset pelatihan yang telah dipilih secara acak.
- Proses *voting*: setiap pohon memberikan prediksi berdasarkan data uji. Hasil akhir diperoleh melalui voting atau pemungutan suara, dengan mayoritas suara menentukan kelas atau nilai prediksi.

Parameter dari algoritma RF adalah  $n\_estimators$ ,  $max\_depth$ , minimal sampel  $split$ , minimal sampel  $leaf$ ,  $max\_features$ , maksimal sampel.

#### 5. *Support vector machine* (SVM)

*Support vector machine* merupakan sistem pembelajaran untuk mengklasifikasikan data menjadi dua kelompok menggunakan fungsi-fungsi linear dalam sebuah ruang fitur berdimensi tinggi menurut Cortes dan Vapnik (1995).

- Pemilihan data pelatihan: memilih dataset pelatihan yang terdiri dari contoh-contoh data dengan label kelas yang telah diketahui.
- Pemilihan kernel (opsional): terdapat empat jenis fungsi kernel yang dapat digunakan (Karatzoglou *et al.* 2005), yaitu linier, *polynomial*, *radial basis function*, (RBF), dan sigmoid.
- Pemisahan data (*optimal margin*): SVM bertujuan untuk menemukan *hyperplane* yang memisahkan data antara kelas dengan margin maksimum.
- Penentuan *hyperplane* optimal: mencari *hyperplane* tersebut dengan memaksimalkan margin sambil meminimalkan kesalahan klasifikasi (yang dikenal sebagai fungsi objektif).
- Prediksi: setelah proses pembelajaran selesai dan *hyperplane* optimal ditemukan, SVM dapat digunakan untuk memprediksi label kelas atau nilai untuk data uji yang belum dilihat sebelumnya.

Parameter dari algoritma SVM adalah parameter regulerisasi (C), fungsi kernel, dan gamma.

### Analisis Model

Pada tahap ini dataset yang digunakan untuk *testing* adalah sejumlah 20% dari total data hasil praproses. Kinerja algoritma diukur menggunakan metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1 Score* (Hossin *et al.* 2015). Perhitungan *accuracy* menggunakan Persamaan 6, *precision* menggunakan Persamaan 7, *recall* menggunakan Persamaan 8 dan nilai *F1 Score* menggunakan Persamaan 9.

$$Accuracy = \frac{TP + TN}{(TP + TN + FP + FN)}, \quad (6)$$

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$Recall = \frac{TP}{TP + FN}, \quad (8)$$

$$F1 \text{ Score} : 2 \times \frac{(Recall * Precision)}{(Recall + Precision)} \quad (9)$$

Keterangan:

TP (*true positive*): jumlah data yang bernilai positif dan diprediksi benar sebagai positif.

TN (*true negative*): jumlah data yang bernilai negatif dan diprediksi benar sebagai negatif.

FP (*false positive*): jumlah data yang bernilai negatif tetapi diprediksi salah sebagai positif.

FN (*false negative*): jumlah data yang bernilai positif tetapi diprediksi salah sebagai negatif.

## HASIL DAN PEMBAHASAN

### Pemodelan Data

Pemodelan data untuk klasifikasi dimulai dengan membagi dataset hasil praproses menjadi dua bagian yaitu 80% untuk *training* dan 20% untuk *testing*. Pada tahap pengembangan model ini, dilakukan proses penyetelan *hyperparameter tuning* untuk mengoptimalkan nilai-nilai parameter pada model klasifikasi. Algoritma ANN, DT, dan RF menggunakan metode *RandomizedSearchCV* karena memiliki ruang parameternya besar sedangkan algoritma KNN dan SVM menggunakan metode *GridSearchCV* karena ruang parameternya yang lebih kecil. Hasil dari penyetelan *hyperparameter tuning* bisa dilihat di Tabel 2.

### Evaluasi Kinerja Model

Nilai matrik evaluasi dari setiap algoritma terhadap penggunaan normalisasi menggunakan metode *Z-score* dapat dilihat pada Tabel 3. Tabel 3 menunjukkan bahwa penggunaan normalisasi data menggunakan metode *Z-score* berhasil meningkatkan performa algoritma klasifikasi dilihat dari meningkatnya nilai matrik evaluasi setiap algoritma. Tabel 3 juga menunjukkan nilai *recall* masih dibawah 80% saat menggunakan metode *Z-score* yang disebabkan oleh *imbalance data* pada dataset. Oleh karena itu, normalisasi data dengan metode *Z-score* dilanjutkan dengan *balancing* menggunakan metode SMOTE dilakukan. Hasil dari matrik evaluasi setelah penggunaan *balancing* menggunakan metode SMOTE menunjukkan peningkatan performa dari setiap algoritma. Terlihat bahwa nilai-nilai pada setiap matrik evaluasi berada di atas 90% setelah penerapan metode *balancing* ini.

Berdasarkan hasil yang diperoleh, kinerja algoritma ANN pada data tanpa normalisasi dan *balancing* menunjukkan performa kurang dari 75%. Namun, terlihat peningkatan kinerja algoritma ANN terlihat ketika diterapkan teknik *balancing* pada algoritma ini sehingga kinerja algoritma mencapai nilai lebih dari 90%. Pada dataset yang tidak seimbang, ANN mengalami kendala karena bobot kelas mayoritas mendominasi proses pembelajaran, sehingga kelas minoritas diabaikan. Sementara, hasil model DT menunjukkan kinerja algoritma yang paling baik dengan nilai matriks evaluasi selalu lebih dari 90% baik pada penggunaan metode praproses ataupun tidak. Meskipun model KNN mencapai sekitar 80% di seluruh data hasil *training*, tetapi kinerja pada data *testing* kurang dari 80%. Peningkatan kinerja KNN terlihat saat normalisasi dan *balancing* pada dataset dilakukan. Sementara, kinerja RF (*precision*, *recall*, dan *F1-score*) berada di bawah 90%, kecuali *accuracy* (96%) saat data belum dilakukan normalisasi dan dilakukan *balancing*. Namun, setelah proses dilakukan *balancing*, kinerja model hasil RF meningkat sehingga di atas 90%. Di samping itu, kinerja hasil model SVM kurang dari 80% saat data belum dinormalisasi dan dilakukan *balancing* karena SVM sensitif terhadap perbedaan skala dalam dataset. Namun, terjadi peningkatan kinerja yang signifikan saat model menggunakan dataset yang telah dinormalisasi dan dilakukan *balancing*.

Tabel 3 Nilai matriks evaluasi setiap algoritma

Algoritma	Matrik evaluasi	Tanpa normalisasi & <i>balancing</i>		Dengan normalisasi		Dengan <i>balancing</i>		Dengan normalisasi & <i>balancing</i>	
		<i>Training</i>	<i>Testing</i>	<i>Training</i>	<i>Testing</i>	<i>Training</i>	<i>Testing</i>	<i>Training</i>	<i>Testing</i>
ANN	<i>Precision</i>	39.28	31.70	99.58	74.50	100.00	99.00	100.00	99.75
	<i>Recall</i>	27.28	27.20	93.15	75.45	100.00	98.75	100.00	99.75
	<i>F1-Score</i>	26.60	26.00	94.65	74.60	100.00	98.75	100.00	99.50
	<i>Accuracy</i>	71.90	70.05	99.10	95.70	100.00	98.80	100.00	99.70
DT	<i>Precision</i>	98.50	94.18	98.20	91.20	99.25	99.25	100.00	99.75
	<i>Recall</i>	98.25	95.55	95.88	92.30	99.25	99.25	100.00	99.75
	<i>F1-Score</i>	98.33	94.68	96.80	91.53	99.00	99.00	100.00	99.50
	<i>Accuracy</i>	98.80	97.90	98.90	97.60	99.10	99.10	100.00	99.70
KNN	<i>Precision</i>	88.18	33.18	100.00	76.58	100.00	84.75	100.00	99.25
	<i>Recall</i>	85.48	26.33	100.00	70.85	100.00	84.50	100.00	99.25
	<i>F1-Score</i>	85.38	24.60	100.00	73.15	100.00	83.75	100.00	99.00
	<i>Accuracy</i>	95.80	78.40	100.00	95.00	100.00	84.60	100.00	99.10
RF	<i>Precision</i>	81.68	79.19	74.53	70.93	97.50	98.25	99.00	98.25
	<i>Recall</i>	78.38	78.66	73.13	70.38	97.50	98.00	99.00	98.00
	<i>F1-Score</i>	78.75	78.62	73.20	70.13	97.50	98.00	99.25	98.00
	<i>Accuracy</i>	97.10	96.00	96.70	95.10	97.40	98.00	99.10	98.00
SVM	<i>Precision</i>	20.20	19.50	99.63	72.88	100.00	84.75	99.75	99.75
	<i>Recall</i>	25.00	25.00	95.93	75.00	100.00	66.25	99.75	99.75
	<i>F1-Score</i>	22.00	22.00	96.68	73.75	100.00	67.00	100.00	99.50
	<i>Accuracy</i>	79.00	78.00	99.50	96.20	100.00	66.30	99.80	99.70

Algoritma klasifikasi terbaik dipilih dengan mempertimbangkan nilai matriks evaluasi dari setiap metode praproses dan rata-rata nilai matriks evaluasi seluruh algoritma. Berdasarkan evaluasi kinerja model, algoritma DT menunjukkan nilai matriks evaluasi lebih dari 90% pada semua metode praproses sehingga pada penelitian ini, algoritma DT terpilih sebagai metode terbaik.

## SIMPULAN

Penelitian ini membandingkan beberapa algoritma klasifikasi untuk memodelkan kebutuhan pupuk N dari data citra multispectral, dengan menggunakan ground truth dari penskalaan BWD. Algoritma klasifikasi yang dibandingkan yaitu DT, ANN, SVM, RF, dan KNN. Evaluasi kinerja kelima algoritma klasifikasi dilakukan dengan evaluasi metrik *accuracy*, *recall*, *precision* dan *F1 score*. Dalam hasil penelitian ini, disimpulkan bahwa model klasifikasi yang menunjukkan kinerja terbaik adalah algoritma DT. Hal ini berlaku baik dalam kondisi data tanpa normalisasi dan *balancing* maupun dengan penerapan normalisasi dan *balancing*, dengan nilai akurasi, *recall*, *precision*, dan *F1-score* yang semua mencapai atau melebihi 90%.

Kajian penelitian selanjutnya bisa dilakukan dengan penambahan jumlah data dalam dataset. Pada penelitian ini terdapat ketidakseimbangan data (*imbalance data*) yang perlu diperhatikan. Oleh karena itu, penelitian selanjutnya diharapkan dapat mengkaji lebih lanjut mengenai metode praproses data dan teknik *resampling* yang diharapkan dapat digunakan untuk mengatasi permasalahan *imbalance* data tersebut.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Direktorat Riset dan Inovasi (DRI) IPB atas dukungan yang diberikan dalam melaksanakan riset ini. Sebagian riset ini didanai oleh Kementerian Pendidikan, Budaya, Riset, dan Teknologi (Kemendikbudristek) melalui Hibah Penelitian Dasar Unggulan Perguruan Tinggi (PDUPT) dengan nomor 001/E5/PG.02.00.PL/2023.

## DAFTAR PUSTAKA

- Ahmed K, Shahidi TR, Alam SMI, Momen S. 2019. Rice leaf disease detection using machine learning techniques. Di dalam: *International Conference on Sustainable Technologies for Industry 4.0* (STI). doi:10.1109/sti47673.2019.9068096.
- Astika IW, Radite PA, Setiawan M, Ardiyansah. Pemetaan keragaman warna daun padi dengan citra yang diambil dari pesawat terbang mini. *Seminar Nasional PERTETA*, Bandung 6-8 Desember 2011. Bandung, Indonesia.
- Balai Pengkajian Teknologi Pertanian Bali. 2017. Cara penggunaan leaf color chart pada padi. [Diakses 14 Juni 2020]. <http://bali.litbang.pertanian.go.id/ind/index.php/info-teknologi/505-cara-penggunaan-bagan-warna-daun-pada-padi>.
- Chawla NV, Bowyer KW, Hall LO, Kegelmeyer WP. 2022. SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*. 16(1):321-57.
- Cortes C, Vapnik V. 1995. Support-vector networks. *Mach Learn*. 20(3):273–297. doi:10.1007/BF00994018.
- Hashimoto N, Saito Y, Maki M, Homma K. 2019. Simulation of Reflectance and Vegetation Indices for Unmanned Aerial Vehicle (UAV) Monitoring of Paddy Fields. *Remote Sens. Japan*. doi:10.3390/rs11182119.
- Haykin S. 1999. *Neural Networks and Learning Machines Third Edition*. Canada: Pearson Education, Inc.
- Hossin M, Sulaiman MN. 2015. A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process*, 5(2), 01–11. doi:10.5121/ijdkp.2015.5201.
- Islam T, Rizan RUB, Tusher YA, Shafiuzzaman M, Alam MH, Syed G. 2020. Nitrogen fertilizer recommendation for paddies through automating the leaf color chart (LCC), (*IJACSA International Journal of Advanced Computer Science and Applications* 11(8).
- Karatzoglou A, Meyer D, Hornik K. 2005. Support vector machines dalam R. *Journal of Statistical Software*. 15:1–28.
- Kreyszig E, Kreyszig H, Norminton EJ. *Advanced Engineering Mathematics*. 10th ed. Hoboken, NJ, USA: Wiley, 2010, p. 1040.
- Quinlan JR. 1986. “Induction of decision trees”. *Machine Learning*. 1(1):81–106
- Sartono B, Syafitri UD. 2010. Metode pohon gabungan: solusi pilihan untuk mengatasi kelemahan pohon regresi dan klasifikasi tunggal. *Forum Statistika dan Komputasi*. 15:1–7.
- Shakhnarovich G, Darrell T, Indyk P. 2005. *Nearest-Neighbor Methods in Learning and Vision*. London: The MIT Press.
- Sondakh J, Janne HW, Syahyuti. 2020. Karakteristik, potensi generasi milenial, dan perspektif pengembangan pertanian presisi di indonesia. *Forum Penelitian Agro Ekonomi*. 38(2):155–166.
- Suyanto. 2019. *Data mining untuk klasifikasi dan klusterisasi data*. Bandung: Informatika.
- Tipones RD, Cruz JCD. 2019. Nutrient Management with Automated Leaf Color Level Assessment and Ambient Light Neutralizer using SVM Classifier. *International Symposium on Multimedia and Communication Technology (ISMAT)*. Quezon City, Philippines. DOI: 10.1109/ISMAT.2019.8836149.

Zha H, Miao Y, Wang T, Li Y, Zhang J, Sun W, Feng Z, Kusnierek K. 2020. Improving Unmanned Aerial Vehicle Remote Sensing-Based Rice Nitrogen Nutrition Index Prediction with Machine Learning. *Remote Sens.*, 12, 215. <https://doi.org/10.3390/rs12020215>.