

Peningkatan Akurasi Identifikasi Penyakit Busuk Pangkal Batang di Perkebunan Kelapa Sawit Menggunakan *Unmanned Aerial Vehicle (UAV)* dan *Machine Learning*

Accuracy Improvement of Basal Stem Rot Disease Identification in Oil Palm Plantation Using Unmanned Aerial Vehicle and Machine Learning

Heri Santoso

Abstrak Penyakit busuk pangkal batang (BSR) yang disebabkan oleh jamur *Ganoderma* sp pada tanaman kelapa sawit masih menjadi penyakit utama dan belum ada tindakan pengendaliannya yang efektif. Perlakuan kultur teknis untuk memperpanjang umur tanaman masih menjadi tindakan utama dalam pengendalian penyakit BSR ini. Ketepatan identifikasi dan klasifikasi tanaman sehat dan terinfeksi penyakit BSR secara cepat dan tepat sangat diperlukan untuk mendukung perlakuan kultur teknis. Penelitian ini melanjutkan penelitian Santoso (2020) untuk identifikasi dan klasifikasi tanaman kelapa sawit sehat dan terinfeksi penyakit BSR dengan menggunakan pendekatan *remote sensing* dari image yang direkam oleh kamera multispektral tiga band dan *machine learning*. Tujuan utama dari penelitian ini adalah meningkatkan akurasi interpretasi tanaman sehat dan terinfeksi penyakit BSR dengan penambahan variabel berupa sepuluh indeks vegetasi yang memanfaatkan ketiga band dari kamera multispektral (merah, hijau, dan *near infrared/NIR*) dan penerapan enam belas *machine learning classification model*. Hasil penelitian menunjukkan model *random forest* dan *stochastic gradient boosting* mampu meningkatkan akurasi interpretasi menjadi 87.18 % dari 79.49 % dan *kappa value* menjadi 0.69 dari 0.48. Peningkatan akurasi ini tidak lepas dari variabel penting dalam fitting model yang digunakan dalam penelitian ini yang didominasi oleh variabel dari indeks vegetasi dan band merah. Model ini perlu diuji untuk mengidentifikasi tanaman sehat dan terinfeksi penyakit BSR dengan taraf

insidensi rendah dan sedang.

Kata kunci: penyakit busuk pangkal batang, kelapa sawit, UAV, multispectral, indeks vegetasi, *machine learning*

Abstract The basal stem rot disease caused by *Ganoderma* sp remains a majority disease in oil palm plantations, and there is no effective treatment. The technical culture becomes a majority treatment to prolong the oil palm life. The identification and classification accuracy of healthy and infected by BSR (unhealthy) oil palm is needed to support the technical culture of treatment. This study is based on Santoso's previous study (2020), which identifies and classifies healthy and unhealthy oil palms using remote sensing from an image of a multispectral camera with three bands and machine learning. This study aims to improve the interpretation accuracy of healthy and unhealthy oil palms by adding ten vegetation indexes from three bands (red, green, and near-infrared/NIR) of a multispectral camera and applying sixteen models of machine learning. The results showed that the random forest and stochastic gradient boosting had improved 87.18% of the interpretation accuracy by 79.49% in the previous research and 0.69 kappa value from 0.48 in the previous research. This study's accuracy and kappa value improvement may be caused by adding variables from the vegetation indexes that become variable importance besides the red band in the fitting model. The model in this study needs to validate for identifying and classifying healthy and unhealthy oil palm caused by BSR in the area with low and moderate incidence.

Keywords: basal stem rot disease, oil palm, UAV, multispectral, vegetation indexes, machine learning

Penulis yang tidak disertai dengan catatan kaki instansi adalah peneliti pada Pusat Penelitian Kelapa Sawit

Heri Santoso (✉)
Pusat Penelitian Kelapa Sawit
Jl. Brigjen Katamso No. 51 Medan 20158 Indonesia
Email: hs_jmp@yahoo.com

PENDAHULUAN

Penyakit busuk pangkal batang (BSR) pada tanaman kelapa sawit yang disebabkan oleh jamur *Ganoderma* sp sampai saat ini masih menjadi penyakit utama di perkebunan kelapa sawit baik di Indonesia maupun Malaysia. Penyakit ini tidak hanya menyerang tanaman kelapa sawit pada generasi kedua atau ketiga, tapi sudah menyerang pada perkebunan kelapa sawit generasi pertama (Hushiarian *et al.*, 2013; Jazuli *et al.*, 2022; Lisnawita *et al.*, 2016; Priwiratama *et al.*, 2014; Surija & Faustine, 2021). Penyakit yang merusak jaringan batang tanaman kelapa sawit dan morfologi tanaman kelapa sawit yang tergolong kelompok monokotil menjadikan penyakit ini sulit diidentifikasi secara dini (*asymptomatic disease*). Gejala yang diidentifikasi secara visual menunjukkan tanaman sudah terserang dan menunggu tanaman mati atau tumbang. Tindakan kultur teknis berupa penimbunan, pembedahan, dan isolasi merupakan perlakuan untuk memperpanjang umur ekonomi tanaman. Identifikasi tanaman kelapa sawit yang terserang penyakit BSR saat ini menjadi kunci dalam pengendaliannya dengan harapan dapat memperpanjang umur tanaman dan mencegah penularan ke tanaman yang masih sehat (Flood *et al.*, 2022; Jazuli *et al.*, 2022; Priwiratama *et al.*, 2014; Siddiqui *et al.*, 2021; Surija & Faustine, 2021).

Identifikasi tanaman kelapa sawit yang terinfeksi penyakit BSR selain menggunakan diagnosis secara langsung di lapangan (manual) juga banyak dilakukan menggunakan pendekatan teknik remote sensing (Liaghat *et al.*, 2014; Santoso, 2020; Santoso *et al.*, 2017, 2019). Pemanfaatan teknik remote sensing yang dikombinasikan dengan machine learning untuk identifikasi penyakit BSR memberikan hasil klasifikasi yang sangat baik terutama penelitian yang menggunakan data citra satelit (Liaghat *et al.*, 2014; Santoso *et al.*, 2017, 2019), sedangkan untuk data dari drone/*unmanned aerial vehicle* (UAV) mempunyai akurasi identifikasi yang sedang (Ahmadi *et al.*, 2022; Santoso, 2020; Wiratmoko *et al.*, 2018). Semakin tinggi akurasi identifikasi penyakit BSR akan memberikan presisi yang baik kepada praktisi dalam menerapkan tindak kultur teknis. Potensi penggunaan drone/UAV untuk mendukung pertanian yang presisi di perkebunan kelapa sawit sangat besar. Dengan demikian, peningkatan akurasi identifikasi tanaman kelapa sawit yang terinfeksi penyakit BSR dengan data dari drone/UAV dan *machine learning* menjadi

tujuan utama dari penelitian ini.

BAHAN DAN METODE

Penelitian ini menggunakan data dari penelitian Santoso (2020) pada tanaman tahun tanam 2002 dengan jumlah pohon sampel sebanyak 478 pohon. Penelitian ini berlokasi di Kebun Percobaan Aek Pantjur Pusat Penelitian Kelapa Sawit yang secara administrasi berada di Tanjung Morawa, Deli Serdang, Sumatera Utara (Gambar 1). Pengambilan sampel tanaman kelapa sawit dan perekaman image (gambar) dengan UAV dan kamera multispectral dilakukan pada tanggal 1 Agustus 2019.

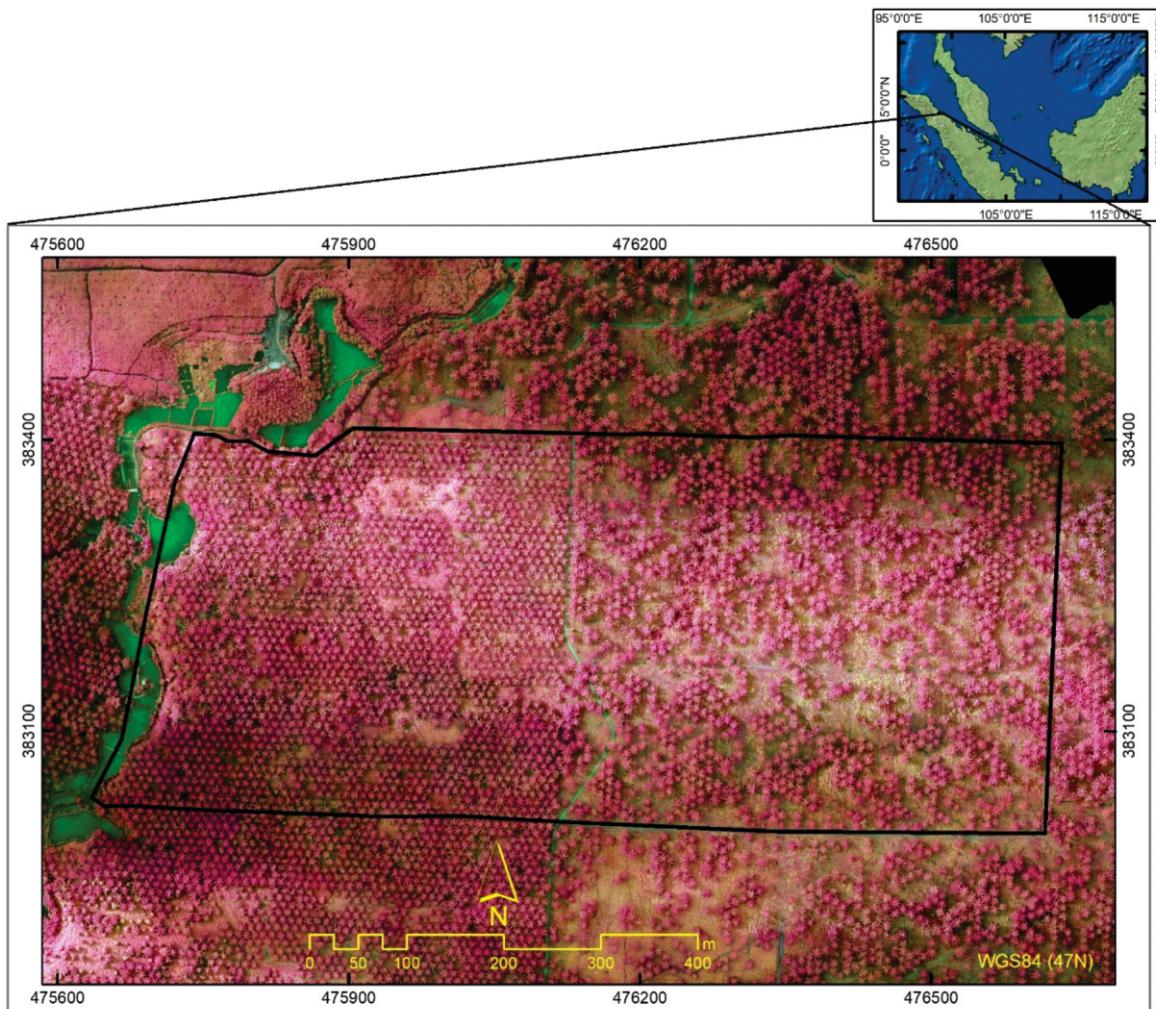
UAV dan kamera multispectral

Wahana (awak) yang digunakan berupa UAV model T-tail vol tron dan kamera yang digunakan adalah Mapir Survey 3 dengan 3 band/saluran (*multispectral*). Tiga saluran (band) tersebut adalah merah (*red/R*) dengan panjang gelombang 660 nm, hijau (*green/G*) dengan panjang gelombang 550 nm, dan infra merah dekat (*near infrared/NIR*) dengan panjang gelombang 850 nm (<https://www.mapir.camera/collections/survey3/products/survey3w-camera-red-green-nir-rgn-ndvi>).

Tinggi terbang diatur pada ketinggian 200 m di atas pemukaan laut dengan overlap antar jalur terbang sebesar 80% dan di dalam jalur 75%. Gambar yang dihasilkan dari perekaman ini mempunyai ukuran piksel 10 x 10 cm. Pada penelitian ini ukuran pixel dikecilkan menjadi 2 x 2 m berdasarkan penelitian (Santoso, 2020; Santoso *et al.*, 2017). Perekaman *calibration reflectance target* (CRT) dilakukan sebelum mulai misi terbang untuk kalibrasi *digital number* (DN) hasil perekaman (image) ke reflectance dengan software *Mapir camera control* (MCC) (<https://www.mapir.camera/pages/calibrating-images-in-mapir-camera-control-application>).

Data tanaman kelapa sawit terinfeksi penyakit BSR

Identifikasi tanaman kelapa sawit dilakukan pada tanaman tahun tanam 2002 sebanyak 478 pohon pada tanggal 1 Agustus 2019 sebagai data referensi (*ground truth*). Penelitian ini menggunakan dua kelas yaitu tanaman sehat dan sakit (terinfeksi penyakit BSR). Kriteria yang digunakan dalam identifikasi tanaman yang terinfeksi penyakit BSR di lapangan



Gambar 1. Lokasi penelitian dan image dari kamera Mapir
Figure 1. Study site and image of Mapir camera

adalah tajuk tanaman tidak membuka > 3 buah, daun menguning dan mengering, pelelah sengkleh, adanya tubuh buah jamur di batang, pangkal batang busuk atau berlobang. Hasil identifikasi menunjukkan sebanyak 313 merupakan tanaman sehat dan 165 tanaman terinfeksi penyakit BSR. Hasil identifikasi tanaman sehat dan sakit dari lapangan tersebut digunakan untuk mengekstraksi nilai pantulan dari masing-masing kanopi tanaman dengan pengekstrak berupa kotak persegi berukuran 5 x 5 meter – . Hasil ekstraksi tersebut berupa nilai pantulan band merah, hijau, dan NIR yang digunakan sebagai variabel dalam model klasifikasi menggunakan *machine learning*.

Variabel dan machine learning

Santoso (2020) menggunakan 3 variabel yaitu band merah (band 1), hijau (band 2), dan NIR (band 3) untuk identifikasi dan klasifikasi tanaman yang sehat dan terinfeksi penyakit BSR dengan *machine learning random forest* (RF). Pada penelitian ini digunakan 13 variabel yaitu band merah, hijau, NIR dan 10 indeks vegetasi sebagai variabel tambahan berdasarkan beberapa penelitian yang menggunakan indeks vegetasi untuk identifikasi penyakit pada berbagai jenis tanaman yaitu *Normalized Difference Vegetation Index* (NDVI), *Green NDVI* (GNDVI), *Simple Ratio* (SR), *Green Chlorophyll Index* (CI), *Green Difference*

Vegetation Index (GDVI), *Green Ratio Vegetation Index* (GRVI), *Modified Simple Ratio* (MSR), *Non-Linear Index* (NLI), *Transformed Difference Vegetation Index* (TDVI), dan *Green enhanced Vegetation Index* (EVI) yang merupakan modifikasi dari EVI dengan mengganti band biru dengan band hijau (Lowe *et al.*, 2017; Lu *et al.*, 2018; Meena *et al.*, 2020; Nikhilraman K, 2022; Pourazar *et al.*, 2019; Wiratmoko *et al.*, 2018). Indeks vegetasi yang digunakan dalam penelitian ini didasarkan pada kombinasi band merah, hijau, dan NIR yang umum digunakan dalam kajian vegetasi. Formula dari indeks vegetasi yang digunakan disampaikan pada Tabel 1.

Untuk mengetahui potensi peningkatan akurasi identifikasi tanaman sehat dan terinfeksi penyakit BSR, pada penelitian ini digunakan 16 *machine*

learning classification model yang biasa digunakan dalam klasifikasi di *Caret package* pada R software (Kuhn, 2019; R Core Team, 2016; RStudio, 2015). Keenambelas *machine learning model* tersebut adalah *random forest* (RF), *classification and regression tree* (CART), *random ferns* (RFerns), *random forest by randomization* (RFR), *naive bayes* (NB), *stochastic gradient boosting* (SGB), *boosted tree* (Bstree), *regularized discriminant analysis* (RDA), *bagged CART* (BCART), *partial least square* (PLS), *Neural Networks with feature extraction* (PCANNET), *Support vector machine* (SVM), *k-Nearest neighbor* (k-NN), *Neural network* (NNET), dan *Model averaged neural network* (avNNET) (Kuhn, 2014, 2015, 2019). Tabel 2 menunjukkan *machine learning classification model* dan *tuning parameters* yang digunakan pada penelitian ini.

Tabel 1. Indeks vegetasi yang digunakan

Table 1. *Vegetation indexes in this study*

Indeks vegetasi	Formula
Difference Vegetation Index (NDVI)	$\frac{NIR - R}{NIR + R}$
Green NDVI (GNDVI)	$\frac{NIR - G}{NIR + G}$
Simple Ratio (SR)	$\frac{NIR}{R}$
Green Chlorophyll Index (CI)	$\frac{NIR}{G} - 1$
Green Difference Vegetation Index (GDVI)	$NIR - G$
Green Ratio Vegetation Index (GRVI)	$\frac{NIR}{G}$
Modified Simple Ratio (MSR)	$\frac{\left(\frac{NIR}{R}\right) - 1}{\left(\sqrt{\frac{NIR}{R}}\right) + 1}$
Non-Linear Index (NLI)	$\frac{NIR^2 - 1}{NIR^2 + 1}$
Transformed Difference Vegetation Index (TDVI)	$\sqrt{0.5 + \frac{NIR - R}{NIR + R}}$
Green enhanced Vegetation Index (EVI)	$2.5 * \frac{(NIR - R)}{(NIR + 6 * R - 7.5 * G + 1)}$

Keterangan: NIR (band3); R = red (band1); G = green (band2)



Pembagian data menjadi 75% untuk *training data* dan 25% untuk *testing data* secara *stratified random sampling* dari kelompok (kelas) tanaman sehat dan terinfeksi penyakit BSR (Liaghate et al., 2014). *Train control* diterapkan pada seluruh model meliputi metode *repeated cross validation* untuk menghindari *over fitting* (*kFold* = 10), *repeated* 10 kali, dan *preprocessing* dengan metode *center* dan *scale* untuk menentukan (*fitting*) parameter terbaik. (Gan et al., 2021; Gromski et al., 2014; Santoso et al.,

2017). Performa klasifikasi dari 16 *machine learning classification model* dievaluasi menggunakan parameter akurasi interpretasi dan *kappa value* dengan *threshold* untuk akurasi interpretasi dan *kappa value* berturut-turut sebesar 79.49 dan 0.48 berdasarkan penelitian Santoso (2020). Akurasi interpretasi dan *kappa value* yang lebih tinggi dari nilai *threshold* menjadi indikator utama keberhasilan penelitian ini.

Tabel 2. Machine learning classification model dan tuning parameters
Table 2. Machine learning classification model and tuning parameters

Model	Method	Tuning parameter
RF	rf	mtry
CART 1	rpart	cp
CART 2	rpart2	maxdepth
RFerns	rFerns	depth
RFR	extraTrees	mtry; numRandomCuts
NB	nb	fL; usekernel; adjust
SGB	gbm	n.trees; interaction.depth; shrinkage; n.minobsinnode
Bstree	bstTree	mstop; maxdepth; nu
RDA	rda	gamma; lamda
BCART	treebag	
PLS	pls	ncomp
PCANNET	pcannet	size; decay
SVM	svmRadial	sigma; cost
k-NN	knn	k
NNET	nnet	size; decay
avNNET	avNNET	size; decay; bag

HASIL DAN PEMBAHASAN

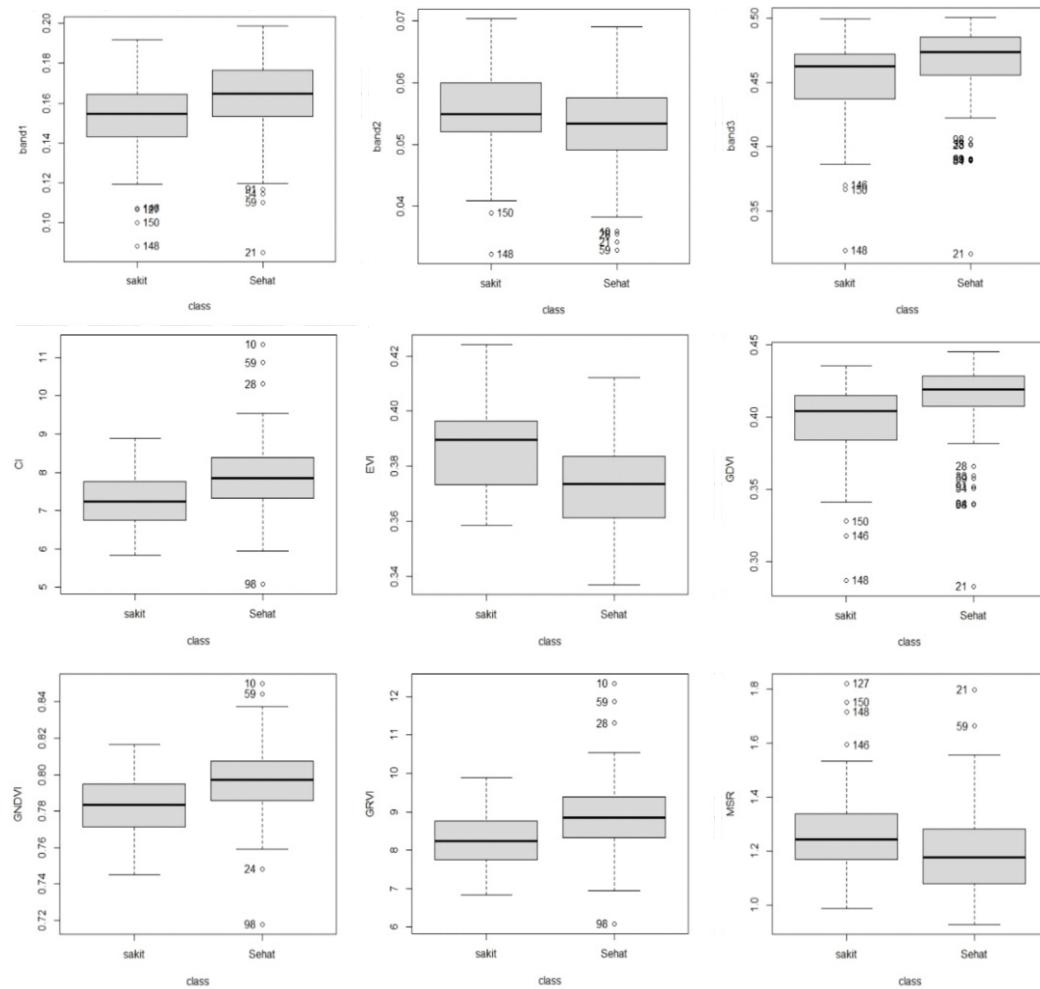
Lokasi penelitian merupakan salah satu kebun dengan tingkat serangan penyakit BSR yang relatif tinggi. Gambar 1 menunjukkan lokasi penelitian dan banyaknya areal terbuka karena tanaman kelapa sawit yang banyak mengalami kematian oleh serangan penyakit BSR. Distribusi data setiap variabel termasuk nilai *minimum*, *quantile* pertama, *median*, *quantile* ketiga, dan nilai maksimum untuk kelas tanaman

kelapa sawit sehat dan terinfeksi penyakit BSR ditunjukkan pada Gambar 2. Interaksi antar varible disampaikan pada Gambar 3. Gambar 2 dan 3 menunjukkan bahwa tanaman sehat dan sakit mempunyai nilai spektral yang saling overlap, sehingga kemampuan mendekripsi dan mengklasifikasikan tanaman yang sehat dan sakit dari 16 *machine learning classification model* sangat penting untuk diketahui. Spektral tanaman yang sehat

dan terifikasi penyakit BSR yang saling overlap juga dijumpai pada penelitian (Santoso et al., 2019).

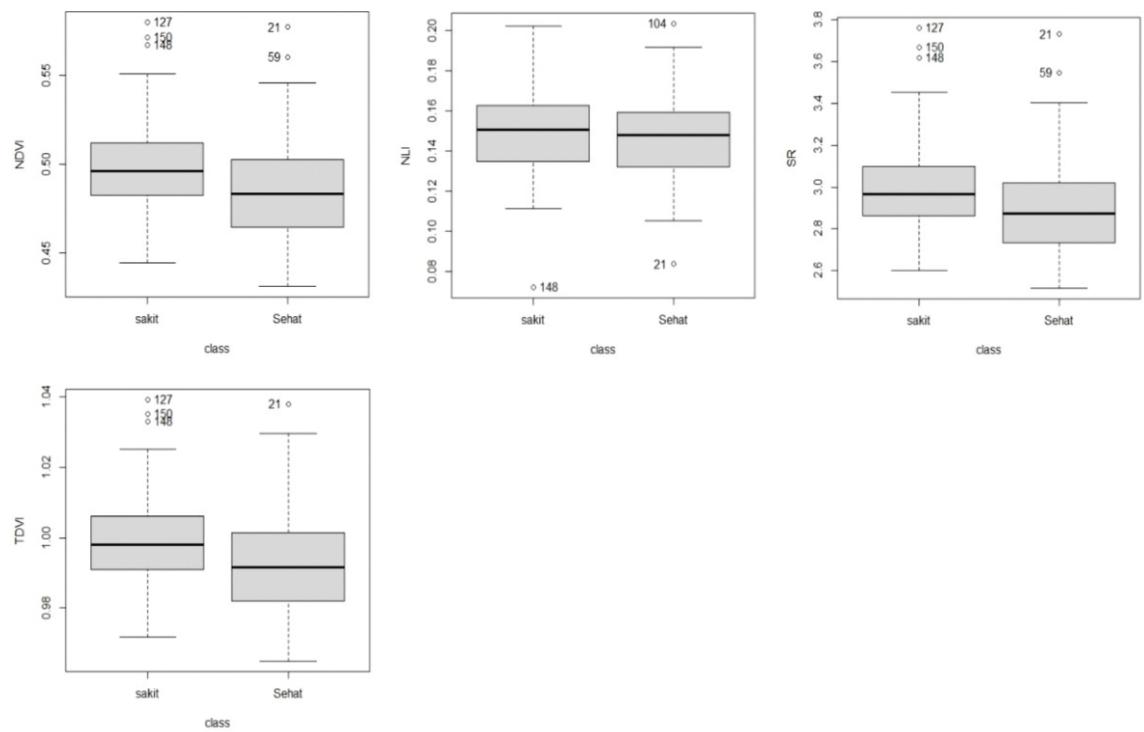
Tuning parameter setiap *machine learning classification model* ditunjukkan pada Tabel 3. Dalam penelitian ini, model memilih *tuning parameter* berdasarkan nilai akurasi yang tertinggi menggunakan *training data*. Pada RF model, terpilih *mtry* = 10, artinya 10 variabel yang terpilih secara random sebagai kandidat dalam proses pemisahan kedua kelas. Model CART 1 mempunyai *tuning parameter* *cp* = 0.08 yang menjelaskan model mengatur dan membangun pohon (*decision tree*) yang relatif besar. Model CART 2 mempunyai *tuning parameter* *maxdepth* = 6 yang berarti model mengkonstruksi pohon (*decision tree*)

sampai pada kedalaman (*depth*) 6. Tuning parameter pada model RFerns adalah *depth* = 3 artinya kedalaman pengacakan dari *fern* yang relatif kecil (tidak memerlukan memory komputer yang tinggi). Model RFR mempunyai *tuning parameter* *mtry* = 1 dan *numRandomCuts* = 1 artinya model memilih secara random 1 variabel dalam memisahkan kedua kelas dengan pemilihan metode pemisahan kedua kelas dari variabel yang terpilih secara sangat random. Model NB mempunyai *tuning parameter* *fL* = 0, *usekernel* = FALSE, dan *adjust* = 1 artinya *Laplace smoother* yang digunakan adalah 1 (selalu ada probabilitas dalam setiap variabel dalam pemisahan kedua kelas), tanpa *kernel* dengan *density* sebesar 1.

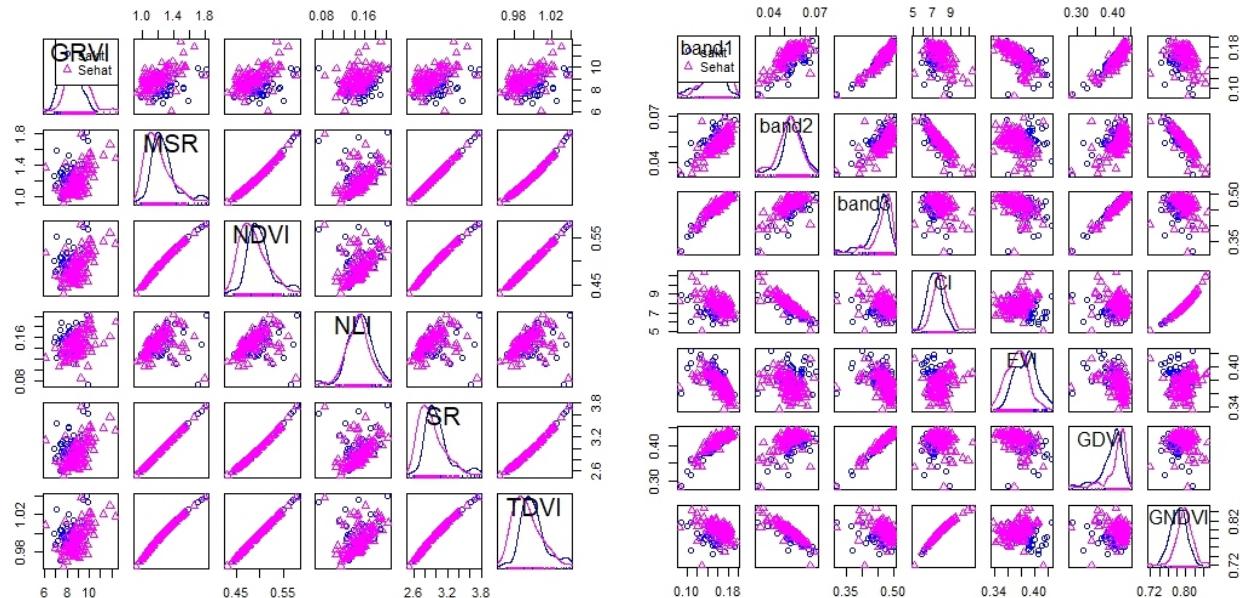


Gambar 2a. Box plot disribusi spectral dari variabel band 1, band 2, band 3, CI, EVI, GDVI, GNDVI, GRVI, dan MSR

Figure 2a. Boxplot of spectral distribution of variables band 1, band 2, band 3, Ci, EVI, GDVI, GNDVI, GRVI, and MSR



Gambar 2b. Box plot disribusi spectral dari variabel NDVI, NLI, SR, dan TDVI
Figure 2b. Boxplot of spectral distribution of variables NDVI, NLI, SR, and TDVI



Gambar 3. Scatterplot spectral dari variabel yang digunakan
Figure 3. Spectral scatterplot of variables

Model SGB mempunyai *tuning parameter* iterasi untuk boosting sebanyak 500 (*n.trees* = 500) dengan kedalaman penyusunan pohon (*decision tree*) sebesar 9 (*interaction.depth* = 9), pembobotan dari setiap pohon (*decision tree*) sebesar 0.1 (*shrinkage* = 0.1) dan jumlah minimal daun (*node*) sebesar 20 (*n.minobsinnode* = 20). Model Bstree mempunyai *tuning parameter* iterasi untuk boosting sebanyak 50 (*mstop* = 50) dengan maksimal

kedalaman pohon (*decision tree*) sebesar 2 (*maxdepth* = 2) dan pembobotan dari setiap pohon (*decision tree*) sebesar 0.001 (*shrinkage* = 0.001). *Tuning parameter* pada model RDA adalah jumlah minimum kehilangan/pengurang dalam proses pembuatan pohon (*decision tree*) sebesar 0.3333 (*gamma*=0.3333) dengan regulasi pada setiap pembobotan sebesar 0.6667 (*lambda*=0.6667).

Tabel 3. *Tuning parameter* pada enam belas *machine learning classification model*
Table 3. *Tuning parameters of the sixteen of machine learning classification model*

Model	Tuning parameter
RF	<i>mtry</i> = 10
CART 1	<i>cp</i> = 0.08
CART 2	<i>maxdepth</i> = 6
RFerns	<i>depth</i> = 3
RFR	<i>mtry</i> = 1; <i>numRandomCuts</i> = 1
NB	<i>fL</i> = 0; <i>usekernel</i> = FALSE; <i>adjust</i> = 1
SGB	<i>n.trees</i> = 500; <i>interaction.depth</i> = 9; <i>shrinkage</i> = 0.1; <i>n.minobsinnode</i> = 20
Bstree	<i>mstop</i> = 50; <i>maxdepth</i> = 2; <i>nu</i> = 0.001
RDA	<i>gamma</i> = 0.3333 and <i>lambda</i> = 0.6667
BCART	-
PLS	<i>Ncomp</i> = 3
PCANNET	<i>size</i> = 3; <i>decay</i> = 0.1
SVM	<i>sigma</i> = 0.2360986 and <i>C</i> = 0.5
k-NN	<i>k</i> = 21
NNET	<i>size</i> = 3; <i>decay</i> = 0.1
avNNET	<i>size</i> = 3; <i>decay</i> = 0.1; <i>bag</i> = FALSE

Model PLS mempunyai *tuning parameter* jumlah komponen untuk mengestimasi variansi (*variances*) sebesar 3 (*ncomp* = 3). Model PCANNET, avNNET, dan NNET mempunyai *tuning parameter* yang serupa yaitu unit tersembunyi (*hidden unit*) sebesar 3 (*size* = 3) dan faktor pembobotan sebesar 0.1 (*decay* = 0.1). Nilai *sigma* = 0.2361 pada model SVM menunjukkan pemisahan antar kelas mengarah ke non-linear dan *cost* = 0.5 menunjukkan aturan/penalty dalam proses

pemisahan kedua kelas yang tergolong soft walaupun akan berdampak kepada hasil akurasi menjadi *underfitting*. Model k-NN mempunyai *tuning parameter* berupa jumlah ketertanggaan yang dilibatkan dalam proses voting sebesar 21 (*k* = 21).

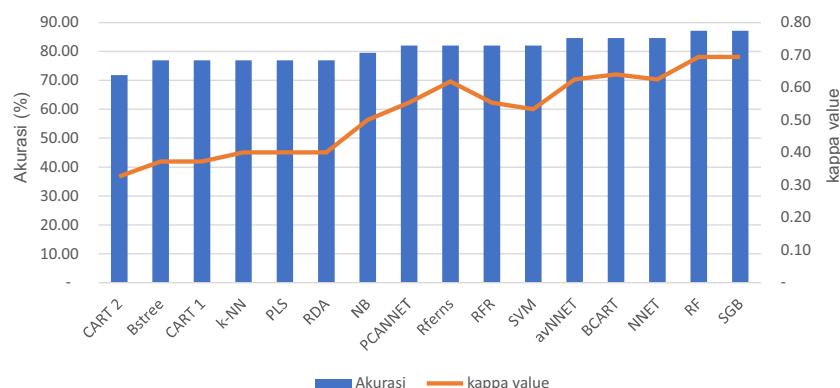
Analisis variabel penting (*variable importance*) dalam mendukung model klasifikasi didapatkan bahwa indek vegetasi mempunyai peran yang penting dalam menyusun model klasifikasi. Berdasarkan nilai

variabel penting dari urutan tertinggi sampai dengan terendah adalah green EVI, CI, band1, GRVI, GNDVI, GDVI, band3, NDVI, MSR, TDVI, NLI, band2, dan SR. Nilai variabel penting dari setiap variabel ditunjukkan pada Tabel 4. Hasil identifikasi dan klasifikasi *machine learning classification model* berdasarkan akurasi interpretasi menunjukkan nilai akurasi bervariasi dari 71.79 – 87.18% dan *kappa value* bervariasi dari 0.33 – 0.69. *Machine learning classification model* yang mempunyai akurasi interpretasi dan *kappa value* di bawah nilai *threshold* 79.49% dan 0.48 sebanyak 7 model yaitu CART 2, Bstree, CART1, k-NN, PLS, RDA,

dan NB. Sembilan model mempunyai akurasi interpretasi dan *kappa value* lebih tinggi dari threshold yaitu PCANNET, Rferns, RFR, SVM, avNNET, BCART, NNET, RF, dan SGB. Jika dikelompokkan berdasarkan akurasi interpretasi, PCANNET, Rferns, RFR, dan SVM mempunyai akurasi interpretasi yang sama yaitu 82.05%. Model avNNET, BCART, dan NNET mempunyai akurasi yang sama yaitu 84.62% serta RF dan SGB mempunyai nilai akurasi interpretasi yang sama yaitu 87.18% dengan *kappa value* sebesar 0.69. Gambar 4 menunjukkan nilai akurasi interpretasi dan *kappa value* seluruh model.

Tabel 4. Variabel penting dalam fitting model klasifikasi
Table 4. Variable importance in the fitting model of classification

Model	Importance
EVI	100
CI	49.309
band1	48.085
GRVI	46.578
GNDVI	39.498
GDVI	37.361
band3	21.248
NDVI	13.783
MSR	13.549
TDVI	11.094
NLI	9.283
band2	5.98
SR	0



Gambar 4. Akurasi interpretasi dan *kappa value* keenambelas model klasifikasi
Figure 4. Interpretation accuracy and kappa value of the sixteen classification models

Pembahasan

Penambahan variabel dari tiga menjadi tigabelas pada penelitian ini memberikan peningkatan akurasi interpretasi dan *kappa value* dibandingkan dengan penelitian Santoso (2020). Model RF yang digunakan pada penelitian Santoso (2020), dengan menggunakan tigabelas variabel pada penelitian ini menunjukkan adanya peningkatan akurasi interpretasi sekitar 9.67 % dan 44.56 % *kappa value*. Penelitian ini sejalan dengan penelitian (Lou et al., 2020) bahwa dengan peningkatan jumlah *variable independent* akan berdampak pada peningkatan akurasi. Jumlah variabel akan berinteraksi dengan dataset yang lain dan akan mempengaruhi performa model klasifikasi (Kwon & Sim, 2013).

Variable importance yang ditunjukkan pada Tabel 4 dengan pengertian *variable importance* sebagai perhitungan scalar dari variabel yang mempengaruhi model klasifikasi (Inglis et al., 2022), maka *Variable importance* yang digunakan dalam penelitian ini mempunyai peran yang cukup sampai tinggi dalam mempengaruhi akurasi interpretasi. Pada penelitian ini,

RF dan SGB mempunyai akurasi yang sama yaitu 87.18% dengan *kappa value* 0.69. Kedua model terbaik pada penelitian ini didasarkan pada *decision tree* dengan perbedaan keduanya terletak pada banyaknya pertumbuhan *tree* dan pengambilan keputusan di akhir proses sebagai rata-rata atau keputusan mutlak (*majority rules*) pada RF dan kombinasi sepanjang proses pada SGB. Model RF dan SGB memberikan hasil akurasi yang sama juga didapatkan oleh penelitian Freeman et al. (2015) dan Shrivastav and Kumar (2022).

Tabel *confusion matrix* pada Tabel 5 menunjukkan peningkatan mayoritas parameter seperti *user's accuracy* (UA), *mapping accuracy*, penurunan *omission* dan *commission error*. Model RF dan SGB dengan penambahan variabel mampu meningkatkan kemampuan mengidentifikasi dan klasifikasi tanaman yang terinfeksi penyakit BSR (sakit) dari 6 obyek menjadi 9 pada penelitian ini. Peningkatan kemampuan tersebut tidak terlepas dari penambahan variable yang berdasarkan lima variabel penting teratas (Tabel 4) adalah green EVI, CI, band1, GRVI, dan GNDVI.

Tabel 5. *Confusion matrix* model RF dan SBG
Table 5. *Confusion matrix of RF and SBG models*

Model	RF (Santoso, 2020)			RF			SGB			
	Predict	Sakit	Sehat	All	Sakit	Sehat	All	Sakit	Sehat	All
Sakit		6	1	7	9	1	10	9	1	10
Sehat		7	25	32	4	25	29	4	25	29
All		13	26	39	13	26	39	13	26	39
PA		46.15%	96.15%		69.23%	96.15%		69.23%	96.15%	
UA		85.71%	78.13%		90.00%	86.21%		90.00%	86.21%	
Mapping Accuracy		42.86	75.76		64.29	83.33		64.29	83.33	
Omission		53.85%	3.85%		30.77%	3.85%		30.77%	3.85%	
Commission		14.29%	21.88%		10.00%	13.79%		10.00%	13.79%	
OA		79.49			87.18			87.18		
Sensitivity		0.4615			0.6923			0.6923		
Specificity		0.9615			0.9615			0.9615		
Kappa		0.48			0.69			0.69		

Keterangan: PA= *producer's accuracy*; UA = *user's accuracy*, OA = *overall accuracy*

Green EVI sebagai variabel teratas dikarenakan indeks vegetasi ini sangat respon terhadap perubahan struktural kanopi tanaman termasuk leaf area index (LAI), type kanopi, fisiognomi tanaman (*plant physiognomy*), dan arsitektur kanopi (Huete *et al.*, 2002). CI dan GRVI memanfaatkan band NIR dan hijau yang beberapa penelitian mampu mengestimasi kandungan klorofil daun (Gitelson *et al.*, 2003, 2005) dan kandungan nitrogen daun Sripada *et al.*, 2006. Kandungan klorofil dan nitrogen daun akan berdampak pada kehijauan daun, sehingga sejalan dengan gejala tanaman kelapa sawit yang terinfeksi penyakit BSR yaitu daun tanaman kelapa sawit yang menguning dan mengering. Tanaman memerlukan cahaya merah dalam menjalankan fotosintesis, sehingga band1 menjadi variabel penting dalam model ini (Lowe *et al.*, 2017; Muneer *et al.*, 2014). Tanaman dengan variasi kandungan klorofil dan variasi dalam menyerap band merah (band1) terutama pada tanaman kelapa sawit yang terinfeksi penyakit BSR mendorong model RF dan SGB mampu meningkatkan kemampuan mengidentifikasi tanaman tersebut. *Kappa value* sebesar 0.69 menunjukkan kepercayaan interpretasi tergolong tinggi berdasarkan (Rwanga and Ndambuki (2017).

KESIMPULAN

Identifikasi tanaman kelapa sawit yang terinfeksi penyakit BSR dengan memanfaatkan UAV dan kamera multispectral Mapir 3 band serta *machine learning* dapat ditngkatkan akurasinya dengan penambahan variabel dari sepuluh indeks vegetasi. *Machine learning model* RF dan SGB memiliki akurasi interpretasi tertinggi dibandingkan dengan 14 model lainnya yaitu 87.18% dengan *kappa value* sebesar 0.69. Model RF dan SGB mampu meningkatkan akurasi interpretasi sebesar 9.67 % dan 44.56% *kappa value* dari penelitian Santoso (2020). Variabel indeks vegetasi menjadi variabel penting dalam *fitting* model RF dan SGB. Adapun lima variabel penting teratas yaitu Green EVI, CI, band1, GRVI, dan GNDVI. Model RF dan SGB perlu diuji untuk mengidentifikasi tanaman sehat dan terinfeksi penyakit BSR dengan taraf insidensi rendah dan sedang.

DAFTAR PUSTAKA

Ahmadi, P., Mansor, S., Farjad, B., & Ghaderpour, E.

- (2022). Unmanned Aerial Vehicle (UAV)-Based Remote Sensing for Early-Stage Detection of Ganoderma. *Remote Sensing*, 14(5), 1–15. <https://doi.org/10.3390/rs14051239>
- Flood, J., Bridge, P. D., & Pilotti, C. A. (2022). Basal stem rot of oil palm revisited. *Annals of Applied Biology*, 181(2), 160–181. <https://doi.org/10.1111/aab.12772>
- Freeman, E. A., Moisen, G. G., Coulston, J. W., & Wilson, B. T. (2015). Random forests and stochastic gradient boosting for predicting tree canopy cover: Comparing tuning processes and model performance. *Canadian Journal of Forest Research*, 46(3), 323–339. <https://doi.org/10.1139/cjfr-2014-0562>
- Gan, Y., Zhang, Y., Kongoli, C., Grassotti, C., Liu, Y., Lee, Y. K., & Seo, D. J. (2021). Evaluation and blending of ATMS and AMSR2 snow water equivalent retrievals over the conterminous United States. *Remote Sensing of Environment*, 254 (October 2020), 112280. <https://doi.org/10.1016/j.rse.2020.112280>
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271–282. <https://doi.org/10.1078/0176-1617-00887>
- Gitelson, A. A., Viña, A., Ciganda, V., Rundquist, D. C., & Arkebauer, T. J. (2005). Remote estimation of canopy chlorophyll content in crops. *Geophysical Research Letters*, 32(8), 1–4. <https://doi.org/10.1029/2005GL022688>
- Gromski, P. S., Xu, Y., Correa, E., Ellis, D. I., Turner, M. L., & Goodacre, R. (2014). A comparative investigation of modern feature selection and classification approaches for the analysis of mass spectrometry data. *Analytica Chimica Acta*, 829, 1–8. <https://doi.org/10.1016/j.aca.2014.03.039>
- Huete, A. R., Didan, K., Miura, T., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83, 195–213.

- Hushiaran, R., Yusof, N. A., & Dutse, S. W. (2013). Detection and control of Ganoderma boninense: strategies and perspectives. *SpringerPlus*, 2(1), 555. <https://doi.org/10.1186/2193-1801-2-555>
- Inglis, A., Parnell, A., & Hurley, C. B. (2022). Visualizing Variable Importance and Variable Interaction Effects in Machine Learning Models. *Journal of Computational and Graphical Statistics*, 31(3), 766–778. <https://doi.org/10.1080/10618600.2021.2007935>
- Jazuli, N. A., Kamu, A., Chong, K. P., Gabda, D., Hassan, A., Abu Seman, I., & Ho, C. M. (2022). A Review of Factors Affecting Ganoderma Basal Stem Rot Disease Progress in Oil Palm. *Plants*, 11(19). <https://doi.org/10.3390/plants11192462>
- Kuhn, M. (2014). *A Short Introduction to the caret Package*. 1–10. <http://caret.r-forge.r-project.org/>
- Kuhn, M. (2015). *Caret. The Comprehensive R Archive Network (CRAN)*. <https://cran.r-project.org/web/packages/caret/caret.pdf>
- Kuhn, M. (2019). *The caret Package*. The Caret Package. <http://topepo.github.io/caret/train-models-by-tag.html#random-forest>
- Kwon, O., & Sim, J. M. (2013). Effects of data set features on the performances of classification algorithms. *Expert Systems with Applications*, 40(5), 1847–1857. <https://doi.org/10.1016/j.eswa.2012.09.017>
- Liaghat, S., Ehsani, R., Mansor, S., Shafri, H. Z. M., Meon, S., Sankaran, S., & Azam, S. H. M. N. (2014). Early detection of basal stem rot disease (Ganoderma) in oil palms based on hyperspectral reflectance data using pattern recognition algorithms. *International Journal of Remote Sensing*, 35(10), 3427–3439. <https://doi.org/10.1080/01431161.2014.903353>
- Lisnawita, Hanum, H., & Tantawi, A. R. (2016). Survey of Basal Stem Rot Disease on Oil Palms (*Elaeis guineensis* Jacq.) in Kebun Bukit Kijang, North Sumatera, Indonesia. *IOP Conference Series: Earth and Environmental Science*, 41, 012007. <https://doi.org/10.1088/1755-1315/41/1/012007>
- Lou, P., Fu, B., He, H., Li, Y., Tang, T., Lin, X., Fan, D., & Gao, E. (2020). An optimized object-based random forest algorithm for marsh vegetation mapping using high-spatial-resolution GF-1 and ZY-3 data. *Remote Sensing*, 12(8). <https://doi.org/10.3390/RS12081270>
- Lowe, A., Harrison, N., & French, A. P. (2017). Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. *Plant Methods*, 13(1), 1–12. <https://doi.org/10.1186/s13007-017-0233-z>
- Lu, J., Ehsani, R., Shi, Y., de Castro, A. I., & Wang, S. (2018). Detection of multi-tomato leaf diseases (late blight, target and bacterial spots) in different stages by using a spectral-based sensor. *Scientific Reports*, 8(1). <https://doi.org/10.1038/s41598-018-21191-6>
- Meena, S. V., Dhaka, V. S., & Sinwar, D. (2020). Exploring the role of vegetation indices in plant diseases identification. *PDGC 2020 - 2020 6th International Conference on Parallel, Distributed and Grid Computing*, 372–377. <https://doi.org/10.1109/PDGC50313.2020.9315814>
- Muneer, S., Kim, E. J., Park, J. S., & Lee, J. H. (2014). Influence of green, red and blue light emitting diodes on multiprotein complex proteins and photosynthetic activity under different light intensities in lettuce leaves (*Lactuca sativa* L.). *International Journal of Molecular Sciences*, 15(3), 4657–4670. <https://doi.org/10.3390/ijms15034657>
- Nikhilraman K. (2022). A Review on Remote Sensing in Successful Crop Disease Monitoring and Management. *International Journal of Innovative Science and Research Technology*, 7(3), 238–244. www.ijisrt.com
- Pourazar, H., Samadzadegan, F., & Dadrass Javan, F. (2019). Aerial multispectral imagery for plant disease detection: radiometric calibration necessity assessment. *European Journal of Remote Sensing*, 52(sup3), 17–31.

- <https://doi.org/10.1080/22797254.2019.1642143>
- Priwiratama, H., Prasetyo, A. E., & Susanto, A. (2014). Pengendalian Penyakit Busuk Pangkal Batang Kelapa Sawit secara Kultur Teknis. *Jurnal Fitopatologi Indonesia*, 10(51), 1–7. <https://doi.org/10.14692/jfi.10.1.1>
- R Core Team. (2016). *R: A Language and Environment for Statistical Computing: Vol. 3.2.2* (R Core Team (ed.); 3.2.2). <https://www.gnu.org/copyleft/gpl.html>. <https://doi.org/https://www.gnu.org/copyleft/gpl.html>
- RStudio. (2015). *Integrated development environment (IDE) for R Code* (0.99.489). RStudio, Inc. <https://www.rstudio.com/products/rstudio/>
- 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>
- Santoso, H. (2020). Pengamatan dan Pemetaan Penyakit Busuk Pangkal Batang di Perkebunan Kelapa Sawit Menggunakan Unmanned Aerial Vehicle (UAV) dan Kamera Multispektral. *Jurnal Fitopatologi Indonesia*, 16(2), 69–80. <https://doi.org/DOI:10.14692/jfi.16.2.69–80>
- Santoso, H., Tani, H., & Wang, X. (2017). Random Forest classification model of basal stem rot disease caused by Ganoderma boninense in oil palm plantations. *International Journal of Remote Sensing*, 38(16), 4683–4699. <https://doi.org/10.1080/01431161.2017.1331474>
- Santoso, H., Tani, H., Wang, X., Prasetyo, A. E., & Sonobe, R. (2019). Classifying the severity of basal stem rot disease in oil palm plantations using WorldView-3 imagery and machine learning algorithms. *International Journal of Remote Sensing*, 40(19: Oil Palms), 1–23. <https://doi.org/10.1080/01431161.2018.1541368>
- Shrivastav, L. K., & Kumar, R. (2022). An Ensemble of Random Forest Gradient Boosting Machine and Deep Learning Methods for Stock Price Prediction. *Journal of Information Technology Research*, 15(1), 1–19. <https://doi.org/10.4018/jitr.2022010102>
- Siddiqui, Y., Surendran, A., Paterson, R. R. M., Ali, A., & Ahmad, K. (2021). Current strategies and perspectives in detection and control of basal stem rot of oil palm. *Saudi Journal of Biological Sciences*, 28(5), 2840–2849. <https://doi.org/10.1016/j.sjbs.2021.02.016>
- Sripada, R. P., Heiniger, R. W., White, J. G., & Meijer, A. D. (2006). Aerial color infrared photography for determining early in-season nitrogen requirements in corn. *Agronomy Journal*, 98(4), 968–977. <https://doi.org/10.2134/agronj2005.0200>
- Surija, S., & Faustine, M. (2021). Basal Stem Rot Disease Eradication and Improving Production with Ganoderma Vaccine/Biofungicide CHIPS in Flooded Area of Oil Palm Plantation. *European Journal of Agriculture and Food Sciences*, 3(3), 101–109. <https://doi.org/10.24018/ejfood.2021.3.3.323>
- Wiratmoko, D., Prasetyo, A. E., Jatmiko, R. H., Yusuf, M. A., & Rahutomo, S. (2018). Identification of Ganoderma boninense Infection Levels on Oil Palm Using Vegetation Index. *International Journal of Oil Palm*, 1(3), 110–120. <https://ijop.id/index.php/ijop/article/view/16>

