



Perbandingan Kinerja Fungsi Kernel Algoritma Support Vector Machine Pada Klasifikasi Penyakit Padi

Kurniawan Saputra¹, Zuriati^{2*}, Sriyanto³

¹Manajemen Informatika, ²Teknik Rekayasa Internet, ³Magister Teknik Informatika

^{1,2} Politeknik Negeri Lampung; Jl. Sukarno Hatta No. 10 Rajabasa Raya Kec. Rajabasa, Kota Bandar Lampung, Lampung 35142 Telepon: (0721) 703995

³ Institut Informatika dan Bisnis Darmajaya; Jl. ZA. Pagar Alam No.93, Kec. Labuhan Ratu, Kota Bandar Lampung, Lampung 35141 Telepon: (0721) 787214

*Email Penulis Korespondensi: zuriati_mi@polinela.ac.id

Abstrak

Penelitian ini bertujuan untuk mengukur dan membandingkan kinerja fungsi kernel algoritma Support Vector Machine (SVM) pada klasifikasi penyakit tanaman padi. Fungsi kernel yang dibandingkan adalah : linear, polinomial, RBF, dan sigmoid. Tahapan penelitian: 1) Pengumpulan data penyakit tanaman padi, 2) Melakukan data embedding, 3) Pembagian data uji dan latih yang dikelompokkan dalam beberapa perbandingan yaitu: 60%:40%, 70%:30%, 80%:20%, dan 90%:10%, 4) Evaluasi menggunakan matrik konfusi, untuk mendapatkan nilai akurasi, presisi, dan recall. Hasil penelitian menunjukkan nilai akurasi tertinggi 89% pada fungsi kernel linear untuk komposisi data 70%:30% dan polinomial untuk komposisi data 80%:20%. Nilai akurasi terendah pada fungsi kernel RBF dengan komposisi data latih dan uji 80%:20% dan 90%:10% senilai 38%. Presisi terbaik pada fungsi kernel linear 90% untuk komposisi data 70%:30%. Nilai presisi terendah pada fungsi kernel RBF dengan komposisi data latih dan uji 80%:20% senilai 41%. Untuk recall terbaik 89% pada fungsi kernel linear untuk komposisi data 60%:40%, 70%:30%, dan 80%:20%. Nilai recall terendah pada fungsi kernel RBF dengan komposisi data latih dan uji 80%:20% dan 90%:10% senilai 38%. Penelitian ini menyimpulkan bahwa SVM dengan fungsi kernel linier memberikan hasil yang baik untuk klasifikasi penyakit tanaman padi.

Kata kunci— Linear, Padi, Polinomial, RBF, Sigmoid, SVM

Abstract

This study aims to measure and compare the performance of the Support Vector Machine (SVM) algorithm kernel function in the classification of rice plant diseases. The kernel functions being compared are linear, polynomial, RBF, and sigmoid. Research stages: 1) Collect data on rice plant diseases, 2) Perform data embedding, 3) Distribution of testing and training data which are grouped into several comparisons, namely: 60%:40%, 70%:30%, 80%:20%, and 90%:10%, 4) Evaluation using the confusion matrix, to get accuracy, precision, and recall values. The results showed that the highest accuracy value was 89% for the linear

kernel function for 70%:30% data composition and polynomials for 80%:20% data composition. The lowest accuracy value in the RBF kernel function with the composition of latih and uji data 80%:20% and 90%:10% is 38%. The best precision is the 90% linear kernel function for 70%:30% data composition. The lowest precision value in the RBF kernel function with the composition of latih and uji data 80%:20% is 41%. For the best recall of 89% on linear kernel functions for data composition 60%:40%, 70%:30%, and 80%:20%. The lowest recall value is in the RBF kernel function with the composition of latih and uji data 80%:20% and 90%:10%, which is 38%. This study concluded that SVM with linear kernel function gave good results for the classification of rice plant disease

Keywords— Linear, Padi, Polinomial, RBF, Sigmoid, SVM

1. PENDAHULUAN

Tanaman padi (*Oryza sativa L.*) adalah sumber pangan utama masyarakat Indonesia, karenanya padi menjadi komoditas perdagangan yang sangat strategis. Indonesia menempati urutan keempat penghasil padi terbesar di dunia dengan memproduksi 35.4 juta metrik ton pertahun. Posisi Indonesia berada di bawah Bangladesh yang menghasilkan 35.85 juta metrik ton, India sejumlah 125 juta metrik ton dan Tiongkok 148.99 juta metrik ton [1].

Tanaman padi rentan terserang hama dan penyakit [2]. Penyakit yang umum menyerang tanaman padi adalah: blas (*Pyricularia oryzae*), hawar daun (*Rhizoctonia solani*), *fusarium sp*, bercak coklat (*Helminthosporium oryzae*) dan penyakit bakteri daun bergaris (*bacterial leaf blight*), *leaf smut* [3],[4]. Penyakit yang menyerang tanaman padi dapat menyebabkan terjadinya gagal panen, sehingga dapat terjadi penurunan jumlah produksi padi. Secara ekonomis dapat menyebabkan kerugian bagi petani dan pemerintah Indonesia. Karena itu perlu melakukan upaya pencegahan penyakit pada tanaman padi [3].

Berbagai upaya telah dilakukan untuk mengatasi masalah penyakit tanaman padi, diantaranya dengan menerapkan ilmu komputer data mining. Algoritma data mining dapat digunakan untuk mengidentifikasi atau mengklasifikasikan jenis penyakit tanaman padi. Hasil penelitian dapat digunakan untuk mengembangkan sebuah model klasifikasi penyakit tanaman padi yang mampu mengidentifikasi jenis penyakit tanaman padi, sehingga dapat dilakukan perawatan dan pemeliharaan sesuai dengan jenis penyakitnya. Salah satu algoritma data mining yang dapat digunakan adalah *Support Vector Machine (SVM)*.

Algoritma SVM memiliki keunggulan karena dapat melakukan pemisahan linear pada input data non linear berdimensi besar, yang diperoleh dengan cara menerapkan fungsi kernel yang sesuai [5],[6], selain itu SVM memiliki kemampuan generalisasi yang sangat baik, dasar teori yang kuat, dan kinerja akurat [7]. Beberapa penerapan algoritma SVM untuk klasifikasi adalah: penyakit stroke [8], klasifikasi teks pengaduan masyarakat [9], deteksi pintu menggunakan *Histogram of Oriented Gradient (HOG)* [10], penundaan biaya kuliah [11], klasifikasi data SAR [12], klasifikasi penerimaan mahasiswa baru [13], klasifikasi data citra wajah berdasarkan suku [14].

Algoritma SVM memiliki 4 fungsi kernel, yaitu: linear, polinomial, Radial Basis Function (RBF), dan sigmoid [15],[16]. Penting sekali untuk menentukan fungsi kernel SVM yang akan digunakan pada pengembangan sebuah model klasifikasi, agar mendapatkan kinerja klasifikasi algoritma SVM yang maksimal. Pemilihan fungsi kernel yang digunakan akan mempengaruhi kinerja model yang dikembangkan, sehingga perlu dilakukan pemilihan fungsi kernel yang memiliki kinerja terbaik [11]. Karena itu penelitian ini melakukan percobaan dengan membandingkan kinerja fungsi kernel SVM pada data citra digital penyakit tanaman padi. Kinerja fungsi kernel SVM dapat dilihat dari nilai akurasi, presisi, dan *recall*. Untuk mendapatkan kinerja SVM terbaik, maka diterapkan skenario pembagian data uji dan data latih, yaitu: 60%:40%, 70%:30%, 80%:20%, dan 90%:10%. Hal ini untuk mengetahui apakah

perbandingan komposisi data latih dan data uji akan berpengaruh pada kinerja fungsi kernel SVM.

Penelitian terdahulu yang telah melakukan perbandingan kinerja fungsi kernel SVM dilakukan oleh [17] untuk analisis sentimen di Instagram dan Twitter. Hasil penelitian menyimpulkan kernel linier memiliki akurasi tertinggi sebesar 83.06%, presisi sebesar 91.04%, dan *recall* sebesar 89.70%. Sedangkan [10] melakukan perbandingan kinerja fungsi kernel untuk mendeteksi pintu berbasis HOG menggunakan fungsi kernel linear, polinomial, dan RBF. Akurasi terbaik sistem deteksi pintu didapatkan pada fungsi kernel RBF sebesar 95%. Selanjutnya, [18] melakukan perbandingan kinerja fungsi kernel SVM untuk klasifikasi *Human Development Index* (HDI). Fungsi kernel terbaik didapatkan oleh RBF senilai 98.1%.

Tahapan penelitian adalah: pengumpulan data citra daun tanaman padi, data *embedding*, pembagian data untuk data uji dan latih, implementasi algoritma SVM, pengujian dan pengukuran kinerja SVM. Penelitian ini bertujuan untuk mengukur dan membandingkan kinerja fungsi kernel SVM dalam mengklasifikasikan jenis penyakit tanaman padi, yaitu penyakit: *leaf smut*, penyakit garis coklat (*brown spot*), dan penyakit bakteri daun bergaris (*bacterial leaf blight*). Hasil penelitian merekomendasikan fungsi kernel dan komposisi data terbaik yang dapat digunakan untuk implementasi perangkat lunak identifikasi penyakit tanaman padi yang dapat digunakan oleh petani dan masyarakat dalam mengidentifikasi penyakit yang menyerang tanaman padi, sehingga petani dan masyarakat dapat dengan mudah melakukan perawatan dan pemeliharaan terhadap tanaman padi sesuai dengan jenis penyakit yang teridentifikasi, sehingga kegagalan panen dapat dihindari.

2. METODE PENELITIAN

Tahapan penelitian adalah: pengumpulan data citra digital daun tanaman padi, melakukan data *embedding*, pembagian data, implementasi algoritma SVM, dan evaluasi. Berikut penjelasan dari setiap tahapan yang dilakukan.

2.1 Pengumpulan Data

Tahap awal dari penelitian adalah pengumpulan data. Data yang digunakan berupa citra digital daun tanaman padi, yang dikumpulkan dari <https://kaggle.com>. Data daun yang dikumpulkan terdiri dari tiga jenis penyakit, yaitu *bacterial leaf blight*, *brown spot* dan *leaf smut*. Pada Gambar 1 disajikan contoh data citra digital daun tanaman padi. Untuk masing-masing jenis penyakit dikumpulkan 40 data citra berekstensi jpeg, sehingga total data berjumlah 120 data.



Gambar 1 Citra Digital Daun Tanaman Padi

2. 2 Data Embedding

Data *embedding* yang dimaksud adalah melakukan presentasi numerik atau angka dari citra daun tanaman padi. Setiap citra memiliki 2048 representasi numerik (kolom n0 hingga n2047). *Embedding* data dilakukan menggunakan *Inception v3*. Hal ini dilakukan untuk memastikan data citra tersebut layak atau tidak digunakan pada penelitian, sehingga kinerja model klasifikasi memiliki tingkat akurasi yang tinggi. Setelah dilakukan proses *embedding* pada 120 data, diketahui tidak terdapat *missing* data, dan dihasilkan 2048 fitur untuk setiap data citra digital daun tanaman padi. Pada Gambar 2 disajikan contoh data hasil *embedding*.

category	image name	image	size	width	height	n0 True	n1 True	n2 True	n3 True
Bacterial leaf bl...	DSC_0403	Bacterial leaf bl...	516994	3081	897	0.0367102	0.0140813	0.123854	0.7556
Bacterial leaf bl...	DSC_0389	Bacterial leaf bl...	469886	3081	897	0.0498063	0.0391739	0.198615	0.1967
Bacterial leaf bl...	DSC_0378	Bacterial leaf bl...	537232	3081	897	0.0522857	0.0532504	0.271143	0.223
Bacterial leaf bl...	DSC_0388	Bacterial leaf bl...	478766	3081	897	0.0544049	0.124512	0.0142996	0.3844
Leaf smut	DSC_0503	Leaf smutDSC...	37101	614	409	0.0557507	0.132784	0.0521576	0.2517
Leaf smut	DSC_0510	Leaf smutDSC...	35243	537	216	0.0567569	0.283261	0.145083	0.2460
Bacterial leaf bl...	DSC_0365	Bacterial leaf bl...	467109	3081	897	0.0636884	0.0182463	0.146108	0.06225
Bacterial leaf bl...	DSC_0703	Bacterial leaf bl...	344286	3081	897	0.0647813	0.00631746	0.165958	0.2677
Bacterial leaf bl...	DSC_0377	Bacterial leaf bl...	388554	3081	897	0.0735724	0.0505691	0.218666	0.3431
Bacterial leaf bl...	DSC_0400	Bacterial leaf bl...	658844	3081	897	0.0746632	0.0454796	0.166963	0.6216
Bacterial leaf bl...	DSC_0381	Bacterial leaf bl...	440993	3081	897	0.0797325	0.0172	0.127724	0.541
Bacterial leaf bl...	DSC_0366	Bacterial leaf bl...	417929	3081	897	0.0811506	0.0489254	0.224	0.1023
Bacterial leaf bl...	DSC_0385	Bacterial leaf bl...	498623	3081	897	0.0930599	0.0877317	0.609839	0.5619
Brown spot	DSC_0112	Brown spotDS...	33490	427	193	0.118409	0.20566	0.316234	0.3398
Bacterial leaf bl...	DSC_0367	Bacterial leaf bl...	452625	3081	897	0.119066	0.0781509	0.335471	0.2708
Bacterial leaf bl...	DSC_0380	Bacterial leaf bl...	484552	3081	897	0.123489	0.000118542	0.136951	0.6533
Leaf smut	DSC_0310	Leaf smutDSC...	423046	3081	897	0.123848	0.0529847	0.0367943	0.5740
Bacterial leaf bl...	DSC_0398	Bacterial leaf bl...	385307	3081	897	0.12559	0.0197847	0.188663	0.1157
Bacterial leaf bl...	DSC_0401	Bacterial leaf bl...	473033	3081	897	0.130021	0.0195827	0.160347	0.3528
Bacterial leaf bl...	DSC_0386	Bacterial leaf bl...	462423	3081	897	0.143827	0.139432	0.213291	0.4299
Bacterial leaf bl...	DSC_0382	Bacterial leaf bl...	451417	3081	897	0.150622	0.0472385	0.145595	0.3438
Brown spot	DSC_0325	Brown spotDS...	384872	3081	897	0.156081	0.107736	0.254753	0.3489
Brown spot	DSC_0306	Brown spotDS...	522154	3081	897	0.162527	0.125701	0.206289	0.787
Bacterial leaf bl...	DSC_0379	Bacterial leaf bl...	432434	3081	897	0.166685	0.0766964	0.190121	0.3989
Bacterial leaf bl...	DSC_0397	Bacterial leaf bl...	460221	3081	897	0.167668	0.0189164	0.270505	0.1951

Gambar 2 Contoh Hasil *Embedding* Citra Digital Daun Padi

2. 3 Pembagian Data

Selanjutnya data dibagi menjadi dua kelompok data yang saling asing, yang akan digunakan untuk data latih dan data uji. Penelitian ini menerapkan 4 skenario pembagian data, seperti yang disajikan pada Tabel 1.

Tabel 1 Skenario Pembagian Data Latih dan Uji

Skenario	Jumlah Data Latih	Jumlah Data Uji
1	60% = 72	40% = 48
2	70% = 84	30% = 36
3	80% = 96	20% = 24
4	90% = 108	10% = 12

2. 4 Algoritma SVM

SVM diperkenalkan oleh Vapnik sebagai konsep dalam bidang *pattern recognition* atau pengenalan pola [15]. SVM memiliki beberapa fungsi kernel, pada penelitian ini fungsi kernel yang digunakan adalah: linier, polinomial, RBF, sigmoid. Penggunaan kernel bertujuan untuk mentransformasikan data ke ruang berdimensi tinggi, dengan menjadikan data non linier terpisah secara linier [15]. Jenis-jenis fungsi kernel SVM [5] yaitu:

a. Linier kernel

Fungsi kernel linier adalah fungsi paling sederhana, merupakan perkalian titik dari dua vektor, dengan persamaan berikut:

$$K(x_i, x_j) = x_i \cdot x_j \quad (1)$$

b. Polynomial kernel

Fungsi kernel polinomial dengan memiliki derajat d , dimana r dan d adalah parameter yang didefinisikan sebagai berikut:

$$K(x_i, x_j) = (\gamma x_i \cdot x_j + r)^d, \quad \gamma > 0 \quad (2)$$

c. RBF

RBF disebut juga sebagai fungsi kernel Gaussian. RBF didefinisikan sebagai berikut:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0 \quad (3)$$

dimana γ adalah parameter positif untuk mengatur jarak.

d. Sigmoid Kernel

Sigmoid kernel didefinisikan sebagai berikut:

$$K(x_i, x_j) = \tanh(\gamma x_i, x_j + r) \quad (4)$$

dimana: $\tanh(a) = 2\sigma(a) - 1$, dan $\sigma(a) = 1 / (1 + \exp(-a))$

2.5 Evaluasi

Pengukuran kinerja SVM dilakukan menggunakan matrik konfusi dengan menggunakan sebuah tabel yang mencatat hasil kinerja kernel SVM. Matrik konfusi berisi data yang membandingkan hasil klasifikasi aktual dan prediksi. Matrik konfusi terdiri dari *True positive* (TP), *False Positive* (FP), *False Negative* (FN), dan *True Negative* (TN). Tabel matrik konfusi disajikan pada Tabel 2.

Tabel 2 Matrik Konfusi

Label Aktual	Label Prediksi	
	1	2
1	True Positif (TP)	False Negatif (FN)
2	False Positif (FP)	True Negatif (TN)

Akurasi adalah tingkat korelasi antara nilai prediksi dengan nilai aktual, sehingga dapat digunakan untuk menghitung keakuratan sistem mengklasifikasikan data dengan tepat. Presisi adalah tingkat ketepatan antara data yang diharapkan oleh pengguna dengan jawaban yang diberikan oleh sistem. Sedangkan *recall* merupakan tingkatan keberhasilan sistem dalam menghitung seberapa banyak nilai kebenaran dari dataset yang memang bernilai benar (positif) muncul. Berikut adalah persamaan matematika untuk menghitung akurasi, presisi, dan *recall*.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$Presisi = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

3. HASIL DAN PEMBAHASAN

Untuk mendapatkan nilai akurasi, presisi, *recall* terbaik dari kernel SVM, maka dalam penelitian ini penulis melakukan implementasi dan pengujian dengan 2 cara, yaitu:

- Skenario perbandingan jumlah data latih dan data uji: 60%:40%, 70%:30%, 80%:20%, 90%:10%.
- Skenario kernel SVM yang digunakan: linear, polinomial, RBF, sigmoid.

3.1 Skenario 60%:40%

Berikut adalah nilai akurasi, presisi, *recall* yang didapatkan untuk skenario pembagian data latih dan uji 60%: 40%, pada setiap kernel SVM.

3.1.1 SVM Linear

Matrik konfusi yang didapatkan untuk fungsi kernel linier pada perbandingan data 60%:40% disajikan pada Gambar 3.

		Predicted			
		Bacterial leaf blight	Brown spot	Leaf smut	
Actual	.	0	0	0	0
	Bacterial leaf blight	0	39	0	1
	Brown spot	0	1	32	7
	Leaf smut	0	0	8	32
Σ		0	40	40	40

Gambar 3 Matrik Konfusi SVM Linear

3. 1.2 SVM Polinomial

Matrik konfusi yang didapatkan untuk fungsi kernel polinomial pada perbandingan data 60% : 40% disajikan pada Gambar 4.

		Predicted			
		Bacterial leaf blight	Brown spot	Leaf smut	
Actual	.	0	0	0	0
	Bacterial leaf blight	0	158	2	0
	Brown spot	0	50	109	1
	Leaf smut	0	50	32	78
Σ		0	258	143	79

Gambar 4 Matrik Konfusi SVM Polinomial

3. 1.3 SVM RBF

Matrik konfusi yang didapatkan untuk fungsi kernel RBF pada perbandingan data 60% : 40% disajikan pada Gambar 5.

		Predicted			
		Bacterial leaf blight	Brown spot	Leaf smut	
Actual	.	0	0	0	0
	Bacterial leaf blight	0	83	77	0
	Brown spot	0	72	88	0
	Leaf smut	0	70	69	21
Σ		0	225	234	21

Gambar 5 Matrik Konfusi SVM RBF

3. 1.4 SVM Sigmoid

Matrik konfusi yang didapatkan untuk fungsi kernel sigmoid pada perbandingan data 60%:40% disajikan pada Gambar 6.

		Predicted		
		Bacterial leaf blight	Brown spot	Leaf smut
Actual	.	0	0	0
	Bacterial leaf blight	0	130	2
	Brown spot	0	11	101
	Leaf smut	0	23	51
Σ		0	164	162

Gambar 6 Matrik Konfusi SVM Sigmoid

3. 2 Skenario 70% : 30%

Berikut adalah matrik konfusi yang didapatkan untuk skenario pembagian data latih dan uji 70%:30%, pada setiap kernel SVM.

3. 2.1 SVM Linear

Matrik konfusi yang didapatkan untuk fungsi kernel linier pada perbandingan data 70%:30% disajikan pada Gambar 7.

		Predicted		
		Bacterial leaf blight	Brown spot	Leaf smut
Actual	.	0	0	0
	Bacterial leaf blight	0	117	2
	Brown spot	0	8	107
	Leaf smut	0	1	22
Σ		0	126	104

Gambar 7 Matrik Konfusi SVM Linear

3. 2.2 SVM Polinomial

Matrik konfusi yang didapatkan untuk fungsi kernel polinomial pada perbandingan data 70%:30% disajikan pada Gambar 8.

		Predicted		
		Bacterial leaf blight	Brown spot	Leaf smut
Actual	.	0	0	0
	Bacterial leaf blight	0	120	0
	Brown spot	0	39	79
	Leaf smut	0	33	29
Σ		0	192	60

Gambar 8 Matrik Konfusi SVM Polinomial

3. 2.3 SVM RBF

Matrik konfusi yang didapatkan untuk fungsi kernel RBF pada perbandingan data 70%:30% disajikan pada Gambar 9.

		Predicted			
		Bacterial leaf blight	Brown spot	Leaf smut	
Actual	Bacterial leaf blight	0	75	45	0
	Brown spot	0	64	56	0
	Leaf smut	0	62	41	17
	Σ	0	201	142	17

Gambar 9 Matrik Konfusi SVM RBF

3. 2.4 SVM Sigmoid

Matrik konfusi yang didapatkan untuk fungsi kernel sigmoid pada perbandingan data 70%:30% disajikan pada Gambar 10.

		Predicted			
		Bacterial leaf blight	Brown spot	Leaf smut	
Actual	Bacterial leaf blight	0	101	2	17
	Brown spot	0	6	70	44
	Leaf smut	0	18	32	70
	Σ	0	125	104	131

Gambar 10 Matrik Konfusi SVM Sigmoid

3. 3 Skenario 80% : 20%

Berikut adalah matrik konfusi yang didapatkan untuk skenario pembagian data latihan dan uji 80%:20%, pada setiap kernel SVM.

3. 3.1 SVM Linear

Matrik konfusi yang didapatkan untuk fungsi kernel linier pada perbandingan data 80%:20% disajikan pada Gambar 11.

		Predicted			
		Bacterial leaf blight	Brown spot	Leaf smut	
Actual	Bacterial leaf blight	0	77	0	3
	Brown spot	0	2	68	10
	Leaf smut	0	2	9	69
	Σ	0	81	77	82

Gambar 11 Matrik Konfusi SVM Linear

3. 3.2 SVM Polinomial

Matrik konfusi yang didapatkan untuk fungsi kernel polinomial pada perbandingan data 80%:20% disajikan pada Gambar 12.

		Predicted		
		Bacterial leaf blight	Brown spot	Leaf smut
Actual	Bacterial leaf blight	0	80	0
	Brown spot	0	19	59
	Leaf smut	0	25	12
	Σ	0	124	71

Gambar 12 Matrik Konfusi SVM Polinomial

3. 3.3 SVM RBF

Matrik konfusi yang didapatkan untuk fungsi kernel RBF pada perbandingan data 80%:20% disajikan pada Gambar 13.

		Predicted		
		Bacterial leaf blight	Brown spot	Leaf smut
Actual	Bacterial leaf blight	0	36	7
	Brown spot	0	30	42
	Leaf smut	0	30	36
	Σ	0	96	115

Gambar 13 Matrik Konfusi SVM RBF

3. 3.4 SVM Sigmoid

Matrik konfusi yang didapatkan untuk fungsi kernel linier pada perbandingan data 80%:20% disajikan pada Gambar 14.

		Predicted		
		Bacterial leaf blight	Brown spot	Leaf smut
Actual	Bacterial leaf blight	0	68	10
	Brown spot	0	3	50
	Leaf smut	0	16	22
	Σ	0	87	79

Gambar 14 Matrik Konfusi SVM Sigmoid

3. 4 Skenario 90% : 10%

Berikut adalah matrik konfusi yang didapatkan untuk skenario pembagian data latih dan uji 90%:10%, pada setiap kernel SVM.

3. 4.1 SVM Linear

Matrik konfusi yang didapatkan untuk fungsi kernel linier pada perbandingan data 90%:10% disajikan pada Gambar 15.

		Predicted		
		Bacterial leaf blight	Brown spot	Leaf smut
Actual	.	0	0	0
	Bacterial leaf blight	0	38	0
	Brown spot	0	2	30
	Leaf smut	0	0	13
Σ		0	40	43
				37

Gambar 15 Matrik Konfusi SVM Linear

3. 4.2 SVM Polinomial

Matrik konfusi yang didapatkan untuk fungsi kernel polinomial pada perbandingan data 90%:10% disajikan pada Gambar 16.

		Predicted		
		Bacterial leaf blight	Brown spot	Leaf smut
Actual	.	0	0	0
	Bacterial leaf blight	0	40	0
	Brown spot	0	15	25
	Leaf smut	0	9	13
Σ		0	64	38
				18

Gambar 16 Matrik Konfusi SVM Polinomial

3. 4.3 SVM RBF

Matrik konfusi yang didapatkan untuk fungsi kernel RBF pada perbandingan data 90%:10% disajikan pada Gambar 17.

		Predicted		
		Bacterial leaf blight	Brown spot	Leaf smut
Actual	.	0	0	0
	Bacterial leaf blight	0	11	29
	Brown spot	0	7	33
	Leaf smut	0	8	31
Σ		0	26	93
				1

Gambar 17 Matrik Konfusi SVM RBF

3. 4.4 SVM Sigmoid

Matrik konfusi yang didapatkan untuk fungsi kernel sigmoid pada perbandingan data 90%:10% disajikan pada Gambar 18.

		Predicted			
		Bacterial leaf blight	Brown spot	Leaf smut	
Actual	Bacterial leaf blight	0	32	0	8
	Brown spot	0	1	27	12
	Leaf smut	0	6	10	24
	Σ	0	39	37	44

Gambar 18 Matrik Konfusi SVM Sigmoid

3. 5 Rangkuman Hasil Pengujian

Pada Tabel 3 disajikan rangkuman nilai akurasi, yang dikelompokkan berdasarkan skenario pembagian data latih dan data uji dan fungsi kernel SVM. Nilai akurasi tertinggi didapatkan pada perbandingan data latih dan data uji 70%:30% dan 80%:20% pada fungsi kernel linear senilai 89%, sedangkan nilai akurasi terendah pada fungsi kernel RBF dengan komposisi data latih dan data uji 80%:20% dan 90%:10% senilai 38%.

Tabel 3 Rangkuman Nilai Akurasi

Rasio Data		Nilai Akurasi Kernel SVM			
Latih	Uji	Linear	Polynomial	RBF	Sigmoid
60%	40%	86%	72%	40%	66%
70%	30%	89%	71%	41%	67%
80%	20%	89%	76%	38%	67%
90%	10%	79%	69%	38%	69%

Pada Tabel 4 disajikan rangkuman nilai presisi, yang dikelompokkan berdasarkan skenario pembagian data latih dan data uji dan fungsi kernel SVM. Nilai presisi tertinggi didapatkan pada perbandingan data latih dan data uji 70%:30% pada fungsi kernel linear senilai 90%, sedangkan nilai presisi terendah pada fungsi kernel RBF dengan komposisi data latih dan data uji 70%:30% senilai 38%.

Tabel 4 Rangkuman Nilai Presisi

Rasio Data		Nilai Akurasi Kernel SVM			
Latih	Uji	Linear	Polynomial	RBF	Sigmoid
60%	40%	89%	79%	58%	66%
70%	30%	90%	77%	58%	67%
80%	20%	89%	80%	41%	66%
90%	10%	79%	76%	60%	70%

Pada Tabel 5 disajikan rangkuman nilai *recall*, yang dikelompokkan berdasarkan skenario pembagian data latih dan data uji dan fungsi kernel SVM. Nilai *recall* tertinggi didapatkan pada perbandingan data latih dan data uji 60%:40%, 70%:30%, dan 80%:20% pada fungsi kernel linear senilai 89%, sedangkan nilai *recall* terendah pada fungsi kernel RBF dengan komposisi data latih dan data uji 80%:20% dan 90%:10% senilai 38%.

Tabel 5 Rangkuman Nilai *Recall*

Rasio Data		Nilai Akurasi Kernel SVM			
Latih	Uji	Linear	Polynomial	RBF	Sigmoid
60%	40%	89%	72%	40%	66%
70%	30%	89%	71%	40%	67%
80%	20%	89%	76%	38%	67%
90%	10%	79%	70%	38%	70%

4. KESIMPULAN

Berdasarkan hasil percobaan maka dapat disimpulkan beberapa hal sebagai berikut:

1. Klasifikasi penyakit tanaman padi dapat dilakukan menggunakan algoritma SVM dengan fungsi kernel linear, polinomial, radial basis function (RBF), dan sigmoid.
2. Komposisi pembagian data latih dan data uji mempengaruhi nilai akurasi, presisi, dan *recall* yang diperoleh.
3. Akurasi algoritma SVM pada klasifikasi penyakit tanaman padi tertinggi didapatkan pada perbandingan data latih dan data uji 70%:30% dan 80%:20% pada fungsi kernel linear senilai 89%, sedangkan nilai akurasi terendah pada fungsi kernel RBF dengan komposisi data latih dan data uji 80%:20% dan 90%:10% senilai 38%.
4. Presisi algoritma SVM pada klasifikasi penyakit tanaman padi tertinggi didapatkan pada perbandingan data latih dan data uji 70%:30% pada fungsi kernel linear senilai 90%, sedangkan nilai presisi terendah pada fungsi kernel RBF dengan komposisi data latih dan data uji 80%:20% senilai 41%.
5. *Recall* algoritma SVM pada klasifikasi penyakit tanaman padi tertinggi didapatkan pada perbandingan data latih dan data uji 60%:40%, 70%:30%, dan 80%:20% pada fungsi kernel linear senilai 89%, sedangkan nilai *recall* terendah pada fungsi kernel RBF dengan komposisi data latih dan data uji 80%:20% dan 90%:10% senilai 38%.
6. Penelitian ini merekomendasikan fungsi kernel linear dapat digunakan untuk implementasi perangkat lunak identifikasi penyakit tanaman padi, karena nilai akurasi, presisi dan *recall* terbaik ada pada fungsi kernel linear.
7. Komposisi pembagian data uji dan data latih terbaik yang direkomendasikan adalah 70%:30%, hal ini karena pada komposisi tersebut, terlihat kinerja fungsi kernel linear untuk akurasi, presisi, dan *recall* adalah tertinggi.

5. SARAN

Saran penelitian selanjutnya dalam klasifikasi penyakit tanaman padi menggunakan algoritma SVM adalah mengintegrasikan teknologi citra atau penginderaan jarak jauh (*remote sensing*) untuk mendapatkan data visual yang lebih mendetail dan luas tentang kondisi tanaman padi. Selain itu, eksplorasi penggunaan teknik pembelajaran mendalam (*deep learning*) untuk klasifikasi penyakit tanaman padi juga dapat menjadi fokus penelitian selanjutnya.

UCAPAN TERIMA KASIH

Terima kasih penulis ucapkan kepada Unit Penelitian dan Pengabdian Masyarakat (UPPM) Polinela yang telah mendanai penelitian ini.

DAFTAR PUSTAKA

- [1] V. B. Kusnandar, “Indonesia Produsen Beras Terbesar ke-4 di Dunia, Juara di ASEAN,” *Kata Data*, hal. 2023, 2023.
- [2] J. Kusanti, K. Penyakit, D. Padi, dan A. Haris, “Klasifikasi Penyakit Daun Padi Berdasarkan Hasil Ekstraksi Fitur GLCM Interval 4 Sudut,” *J. Inform. J. Pengemb. IT*, vol. 03, no. 01, hal. 1–6, 2018.
- [3] A. Walascha, A. Febriana, D. Saputri, D. Sri Nur Haryanti, R. Tsania, dan Y. Sanjaya, “Review Artikel: Inventarisasi Jenis Penyakit yang Menyerang Daun Tanaman Padi (*Oryza sativa L.*),” *Pros. Semin. Nas. Biol.*, vol. 1, no. 2, hal. 471–478, 2022.
- [4] Sudir, A. Nasution, Santoso, dan B. Nuryanto, “Penyakit blas *Pyricularia grisea* pada tanaman padi dan strategi pengendaliannya [Rice blast disease and its control strategy],” *Iptek Tanam. Pangan*, vol. 9, no. 2, hal. 85–96, 2014.
- [5] M. Awad dan R. Khanna, *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, no. April. 2015.
- [6] E. Indrayuni, “Komparasi Algoritma Naive Bayes Dan Support Vector Machine Untuk Analisa Sentimen Review Film,” *J. Pilar Nusa Mandiri*, vol. 14, no. 2, hal. 175, 2018.
- [7] X. Wu *et al.*, *Top 10 algorithms in data mining*, vol. 14, no. 1. 2008.
- [8] K. R. Sulaeman, C. Setianingsih, dan R. E. Saputra, “Analisis Algoritma Support Vector Machine Dalam Klasifikasi Penyakit Stroke,” *eProceedings Eng.*, vol. 9, no. 3, hal. 922–928, 2022.
- [9] I. Istiadi dan A. Y. Rahman, “Optimisasi Parameter Support Vector Machine Berbasis Algoritma Genetika pada Klasifikasi Teks Pengaduan Masyarakat,” *Conf. Innov. Appl. Sci. Technol.*, no. Ciastech, hal. 481–488, 2020.
- [10] A. Zeputra dan F. Utaminigrum, “Perbandingan Akurasi untuk Deteksi Pintu berbasis HOG dengan Klasifikasi SVM menggunakan Kernel Linear , Radial Basis Function dan Polinomial pada Raspberry Pi,” vol. 5, no. 11, hal. 4746–4757, 2021.
- [11] W. Widayani dan H. Harliana, “Analisis Support Vector Machine Untuk Pemberian Rekomendasi Penundaan Biaya Kuliah Mahasiswa,” *J. Sains dan Inform.*, vol. 7, no. 1, hal. 20–27, 2021.
- [12] B. Yekkehkhany, A. Safari, S. Homayouni, dan M. Hasanlou, “A comparison study of different kernel functions for SVM-based classification of multi-temporal polarimetry SAR data,” *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 40, no. 2W3, hal. 281–285, 2014.
- [13] O. D. Amelia, A. M. Soleh, dan S. Rahardiantoro, “Pemodelan Support Vector Machine Data Tidak Seimbang Keberhasilan Studi Mahasiswa Magister IPB,” *Xplore J. Stat.*, vol. 2, no. 1, hal. 33–40, 2018.
- [14] S. Hartono, A. Perwitasari, dan H. Sujaini, “Komparasi Algoritma Nonparametrik untuk Klasifikasi Citra Wajah Berdasarkan Suku di Indonesia,” *J. Edukasi dan Penelit. Inform.*, vol. 6, no. 3, hal. 337, 2020.
- [15] Vapnik dan V. N., “The Nature of Statistical Learning,” *Theory*. hal. 334, 1995.
- [16] S. Agarwal, *Data mining: Data mining concepts and techniques*. 2014.
- [17] A. Z. Praghakusma dan N. Charibaldi, “Komparasi Fungsi Kernel Metode Support Vector Machine untuk Analisis Sentimen Instagram dan Twitter (Studi Kasus : Komisi Pemberantasan Korupsi),” *JSTIE (Jurnal Sarj. Tek. Inform.*, vol. 9, no. 2, hal. 88, 2021.
- [18] H. Al Azies, D. Trishnanti, dan E. Mustikawati P.H, “Comparison of Kernel Support Vector Machine (SVM) in Classification of Human Development Index (HDI),” *IPTEK J. Proc. Ser.*, vol. 0, no. 6, hal. 53, 2019.