



Optimasi Metode Support Vector Machine Linear Dengan Algoritma Pada Klasifikasi Tingkat Obesitas

Ratih Nuur Azizah¹, Basuki Rahmat², Hendra Maulana³

^{1,2,3} Universitas Pembangunan Nasional “Veteran” Jawa Timur Indonesia

Abstract

Received: 3 Oktober 2024
Revised: 12 Oktober 2024
Accepted: 29 Oktober 2024

Obesitas telah menjadi salah satu masalah yang cukup serius diseluruh dunia. Obesitas juga dapat memicu berbagai penyakit lain seperti diabetes, jantung dan kanker. Pola makan dan aktifitas fisik yang tidak teratur merupakan salah satu faktor dari obesitas. Oleh karena itu pemahaman tentang hubungan antara pola makan, kondisi fisik, dan tingkat obesitas menjadi krusial untuk pengembangan strategi pencegahan obesitas yang efektif. Dalam jurnal ini klasifikasi dilakukan menggunakan metode *Support Vector Machine Linear* beserta metode optimasi Algoritma Genetika dipilih untuk membantu menangani masalah tersebut. Sesuai dengan hasil penelitian akurasi tertinggi didapat pada metode *Support Vector Machine Linear* dengan optimasi Algoritma Genetika sebesar 97.9 dengan jumlah populasi 10 serta pembagian data uji dan latih sebesar 80:20. Berdasarkan hasil tersebut metode *Support Vector Machine Linear* yang dioptimasi dengan Algoritma Genetika mampu mengklasifikasikan tingkat obesitas dan dapat meningkatkan nilai akurasi.

Keywords: Obesitas, Optimasi, *Support Vector Machine*, Algoritma Genetika

(*) Corresponding Author: basukirahmat.if@upnjatim.ac.id

How to Cite: Azizah, R., Rahmat, B., & Maulana, H. (2024). Optimasi Metode Support Vector Machine Linear Dengan Algoritma Pada Klasifikasi Tingkat Obesitas. *Jurnal Ilmiah Wahana Pendidikan*, 10(24), 469-477. Retrieved from <https://jurnal.peneliti.net/index.php/JIWP/article/view/9286>

PENDAHULUAN

Obesitas, sebagai pandemi global, telah menjadi masalah kesehatan yang semakin serius dan kompleks di seluruh dunia. Selama lima puluh tahun terakhir, angka kelebihan berat badan dan obesitas terus mengalami peningkatan, dan tingkat obesitas global melonjak tiga kali lipat sejak tahun 1975, mencapai proporsi pandemi (Moschonis et al., 2023). Diperkirakan pada tahun 2030, jumlah orang dengan kelebihan berat badan akan mencapai 2,16 miliar, sementara yang mengalami obesitas diperkirakan mencapai 1,12 miliar di seluruh dunia (Toro Lafia et al., 2022). Selain itu obesitas juga menjadi faktor risiko utama untuk berbagai penyakit kronis seperti penyakit jantung, diabetes tipe 2, dan beberapa jenis kanker. Bukan hanya didunia saja peningkatan angka obesitas terjadi, namun di Indonesia sendiri angka obesitas dan kelebihan berat badan terus melonjak tiap tahunnya. Pada tahun 2013, sebanyak 11,5% dari populasi Indonesia yang berusia di atas 18 tahun mengalami kelebihan berat badan, dan pada tahun 2018, angka ini meningkat menjadi 13,6%. Sementara itu, prevalensi obesitas juga mengalami peningkatan dari 10,5% pada tahun 2007, 14,8% pada tahun 2013, hingga mencapai 21,8% pada tahun 2018 (Octarine et al., 2022).

Pola makan dan kondisi fisik merupakan faktor penting dalam perkembangan dan pencegahan obesitas. Pola makan yang tidak seimbang, konsumsi makanan tinggi lemak dan gula, serta kurangnya aktivitas fisik dapat menyebabkan penumpukan berlebihan lemak dalam tubuh. Oleh karena itu, pemahaman mendalam terkait hubungan antara pola makan, kondisi fisik, dan



tingkat obesitas menjadi krusial untuk pengembangan strategi pencegahan dan intervensi yang efektif.

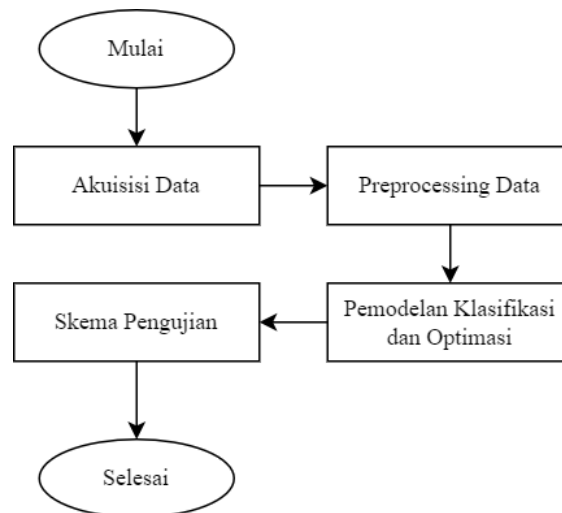
Dalam hal ini, metode klasifikasi menjadi suatu pendekatan yang dapat memberikan pemahaman yang lebih mendalam terhadap karakteristik individu dan faktor-faktor yang berkontribusi pada tingkat obesitas. *Support Vector Machine* (SVM), sebagai metode yang efisien, telah berhasil diterapkan dalam berbagai konteks, termasuk bidang kesehatan. Keunggulan SVM dalam menangani data yang kompleks dan nonlinier membuatnya menjadi pilihan yang menarik untuk digunakan dalam mengklasifikasikan tingkat obesitas. Kemudian untuk meningkatkan nilai akurasi, digunakan metode optimasi Algoritma Genetika.

Pada penelitian yang telah dilakukan sebelumnya terkait klasifikasi tipe berat tubuh menggunakan metode *Support Vector Machine* yang dilakukan oleh Taufik dan Lestari, data yang digunakan ada sebanyak 252 data yang berasal dari pria dengan umur berkisar 22-28 tahun dengan pembagian dataset rasio 70% data training dan 30% data testing. Hasil yang didapatkan dari penelitian tersebut adalah nilai akurasi sebesar 92,11% (Hidayatulloh et al., 2023). Pada penelitian lain yang dilakukan oleh Chattarjee dan kawan-kawan membahas tentang identifikasi faktor resiko pada obesitas dan berat badan berlebih menggunakan machine learning, terdapat 5 jenis dataset, 6 jenis algoritma klasifikasi, dan 6 jenis algoritma regresi berbeda yang digunakan. Berdasarkan hasil yang didapatkan, algoritma klasifikasi *Support Vector Machine* kernel linear memiliki akurasi tertinggi pada 3 jenis dataset. Dan kesimpulan yang dapat diambil dari penelitian tersebut adalah pada dataset yang terbatas, algoritma *Decision Tree* dan SVM (kernel Linear) memiliki performa yang lebih baik daripada algoritma lain (Chattarjee et al., 2020). Selain itu metode optimasi Algoritma Genetika telah terbukti dapat meningkatkan hasil akurasi pada penelitian yang dilakukan oleh Yudi, Dia, dan Dani membahas klasifikasi varietas kismis menggunakan metode *Support Vector Machine* (SVM) yang dioptimalkan melalui seleksi fitur menggunakan Algoritma Genetika (GA). Dataset yang digunakan berasal dari *UCI Machine Learning Repository*, terdiri dari 900 data varietas anggur dengan 8 atribut dan 1 label yang dibagi menjadi kelas Kecimen dan Besni. Sebelum menerapkan GA-SVM, dilakukan eksperimen dengan berbagai metode, termasuk Naïve Bayes, K-NN, *decision tree*, *neural network*, SVM, dan random forest untuk tujuan perbandingan. Hasil pengujian menunjukkan bahwa SVM memiliki kinerja yang superior dibandingkan dengan metode lain, dengan akurasi mencapai 87,11% dan AUC sebesar 0,928. Selanjutnya, pada pengujian SVM dengan optimasi seleksi fitur menggunakan GA, dengan variasi rasio pembagian data antara 0,5 hingga 0,9, SVM menunjukkan peningkatan kinerja. Algoritma SVM menghasilkan nilai rata-rata sebesar 91,56% untuk akurasi, 94,79% untuk presisi, 87,98% untuk recall, dan 0,953 untuk AUC. Validasi dengan rasio pembagian data sebesar 0,9 memberikan hasil akhir yang paling superior dibandingkan dengan rasio lainnya (Ramdhani et al., 2023).

Dengan memadukan informasi pola makan dan kondisi fisik dalam analisis klasifikasi obesitas menggunakan algoritma *Support Vector Machine* dan optimasi menggunakan metode Algoritma Genetika, diharapkan penelitian ini dapat memberikan wawasan terkait faktor pengaruh obesitas dalam kehidupan sehari-hari dan dapat meningkatkan kesadaran masyarakat terhadap risiko obesitas dengan mempertimbangkan beberapa faktor utama dari gaya hidup mereka. Temuan dari

penelitian ini diharapkan dapat menjadi landasan untuk pengembangan yang lebih terarah dan personal dalam upaya menangani obesitas, meningkatkan kualitas hidup, dan mengurangi risiko penyakit terkait obesitas di tingkat individu dan masyarakat secara luas.

METODE PENELITIAN



Gambar 1. Flowchart metode penelitian

Pada penelitian ini metode yang dilakukan terdiri dari beberapa tahap, yaitu, akuisisi data, *preprocessing data*, pemodelan klasifikasi dan optimasi, dan skema pengujian. Tahapan penelitian tersebut dapat dilihat pada gambar 1.

1. Akuisisi Data

Dataset yang digunakan pada penelitian ini berisi tentang estimasi Tingkat obesitas berdasarkan kebiasaan makan dan kondisi fisik Masyarakat Mexico, Peru, dan Colombia. Data obesitas ini didapatkan melalui platform *UCI Machine Learning Repository* dengan bentuk file dalam format “.csv”. Data ini memiliki 17 atribut dan 2111 data yang diambil dari individu berusia mulai dari 14 tahun sampai 61 tahun.

2. *Preprocessing Data*

Setelah melakukan analisis data, selanjutnya dilakukan tahap praproses data. Pada tahap praproses ini dilakukan beberapa hal seperti pengecekan nilai null pada data, mengecek dan menghapus duplikasi data, melabeli data, dan normalisasi atau standarisasi data. Tujuannya adalah untuk menyelaraskan rentang nilai atribut, meminimalkan efek dari atribut dengan skala yang berbeda, dan menjaga keseimbangan data sehingga menghasilkan data yang lebih bersih dan relevan

3. Pemodelan Klasifikasi dan Optimasi

Setelah melakukan *preprocessing data*, selanjutnya dilakukan tahap klasifikasi menggunakan algoritma *Support Vector Machine* (SVM) dan optimasi Algoritma Genetika (GA) pada klasifikasi obesitas. Berikut ini merupakan Langkah-langkah dari algoritma *Support Vector Machine* (SVM) dan optimasi Algoritma Genetika (GA) pada klasifikasi obesitas.

4. Skema Pengujian

Penelitian ini akan melakukan berbagai skenario pengujian dengan variasi arsitektur dan parameter. Parameter yang dioptimalkan menggunakan Algoritma Genetika adalah C dan γ , dengan rentang nilai 0-100 untuk keduanya. Selain itu, dilakukan berbagai jenis pembagian data untuk tiap metode, serta penyesuaian jumlah populasi untuk parameter Algoritma Genetika (GA). Menurut Darmawan et al. (2023), jumlah populasi sangat mempengaruhi performa GA. Kernel linear juga dipilih dalam penelitian ini, karena penelitian sebelumnya oleh Chattarjee et al. (2020) menunjukkan bahwa kernel linear efektif dalam mengklasifikasikan masalah obesitas, meskipun menggunakan dataset yang berbeda. Evaluasi pengujian dilakukan menggunakan *confusion matrix* untuk mengukur akurasi, *presisi*, *recall*, dan *F-1 Score*.

Tabel 1. Skenario Pengujian

Metode	Populasi	Data Training	Data Testing
<i>Support Vector Machine</i>	-	90%	10%
		80%	20%
		70%	30%
<i>Support Vector Machine Linear</i>	-	90%	10%
		80%	20%
		70%	30%
<i>Support Vector Machine Linear & Algoritma Genetika</i>	5	90%	10%
		80%	20%
		70%	30%
	10	90%	10%
		80%	20%
		70%	30%
	25	90%	10%
		80%	20%
		70%	30%

HASIL DAN PEMBAHASAN

1. Akuisisi Data

Langkah pertama yang dilakukan adalah melakukan akuisisi data. Data yang digunakan diambil dari UCI *Machine Learning Repository* dengan bentuk file dalam format “.csv”. Jumlah kelas dalam data tersebut sebanyak 7 kelas yang meliputi *Insufficient Weight, Normal Weight, Over Weight I, Over Weight II, Obesity Type I, Obesity Type II, dan Obesity Type III*. Sementara untuk variabelnya sebanyak 16 dengan total keseluruhan data sebanyak 2111 data.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R
1	Gender	Age	Height	Weight	family_history	FAVC	FCVC	NCP	CAEC	SMOKE	CH2O	SCC	FAF	TUE	CALC	MTRANS	NOBeyesdad	
2	Female	21	1.62	64	yes	no	2	3	Sometimes	no	2	no	0	1	no	Public_Transportation	Normal_Weight	
3	Female	21	1.52	56	yes	no	3	3	Sometimes	yes	3	yes	3	0	Sometimes	Public_Transportation	Normal_Weight	
4	Male	23	1.8	77	yes	no	2	3	Sometimes	no	2	no	2	1	Frequently	Public_Transportation	Normal_Weight	
5	Male	27	1.8	87	no	no	3	3	Sometimes	no	2	no	2	0	Frequently	Walking	Overweight_Level_I	
6	Male	22	1.78	89.8	no	no	2	1	Sometimes	no	2	no	0	0	Sometimes	Public_Transportation	Overweight_Level_II	
7	Male	29	1.62	53	no	yes	2	3	Sometimes	no	2	no	0	0	Sometimes	Automobile	Normal_Weight	
8	Female	23	1.5	55	yes	yes	3	3	Sometimes	no	2	no	1	0	Sometimes	Motorbike	Normal_Weight	
9	Male	22	1.64	53	no	no	2	3	Sometimes	no	2	no	3	0	Sometimes	Public_Transportation	Normal_Weight	
10	Male	24	1.78	64	yes	yes	3	3	Sometimes	no	2	no	1	1	Frequently	Public_Transportation	Normal_Weight	
11	Male	22	1.72	68	yes	yes	2	3	Sometimes	no	2	no	1	1	no	Public_Transportation	Normal_Weight	
12	Male	26	1.85	105	yes	yes	3	3	Frequently	no	3	no	2	2	Sometimes	Public_Transportation	Obesity_Type_I	
13	Female	21	1.72	80	yes	yes	2	3	Frequently	no	2	yes	2	1	Sometimes	Public_Transportation	Overweight_Level_II	
14	Male	22	1.65	56	no	no	3	3	Sometimes	no	3	no	2	0	Sometimes	Public_Transportation	Normal_Weight	
15	Male	41	1.8	99	no	yes	2	3	Sometimes	no	2	no	2	1	Frequently	Automobile	Obesity_Type_I	
16	Male	23	1.77	60	yes	yes	3	1	Sometimes	no	1	no	1	1	Sometimes	Public_Transportation	Normal_Weight	
17	Female	22	1.7	66	yes	no	3	3	Always	no	2	yes	2	1	Sometimes	Public_Transportation	Normal_Weight	
18	Male	27	1.93	102	yes	yes	2	1	Sometimes	no	1	no	1	0	Sometimes	Public_Transportation	Overweight_Level_II	
19	Female	29	1.53	78	no	yes	2	1	Sometimes	no	2	no	0	0	no	Automobile	Obesity_Type_I	
20	Female	30	1.71	82	yes	yes	3	4	Frequently	yes	1	no	0	0	no	Automobile	Overweight_Level_II	
21	Female	23	1.65	70	yes	no	2	1	Sometimes	no	2	no	0	0	Sometimes	Public_Transportation	Overweight_Level_I	

Gambar 2. Dataset

2. Preprocessing Data

Praproses data dilakukan untuk memperoleh data yang bersih dan siap digunakan dalam penelitian. Tahapan praproses meliputi pengecekan data kosong, pengecekan data duplikat, *label encoding*, dan normalisasi data.

a. Label Encoding

Tujuan *Label Encoding* adalah mengonversi label atau kategori dalam data menjadi nilai numerik. Metode ini sangat berguna ketika kita memiliki variabel target atau fitur kategori yang perlu diubah menjadi format numerik agar dapat diproses oleh model *machine learning*.

	Gender	Age	Height	Weight	family_history	FAVC	FCVC	NCP	CAEC	SMOKE	CH2O	SCC	FAF	TUE	CALC	MTRANS	NOBeyesdad
0	0	21.0	1.62	64.0	1	0	2.0	3.0	2	0	2.0	0	0.0	1.0	3	3	1
1	0	21.0	1.52	56.0	1	0	3.0	3.0	2	1	3.0	1	3.0	0.0	2	3	1
2	1	23.0	1.80	77.0	1	0	2.0	3.0	2	0	2.0	0	2.0	1.0	1	3	1
3	1	27.0	1.80	87.0	0	0	3.0	3.0	2	0	2.0	0	2.0	0.0	1	4	5
4	1	22.0	1.78	89.8	0	0	2.0	1.0	2	0	2.0	0	0.0	0.0	2	3	6
5	1	29.0	1.62	53.0	0	1	2.0	3.0	2	0	2.0	0	0.0	0.0	2	0	1
6	0	23.0	1.50	55.0	1	1	3.0	3.0	2	0	2.0	0	1.0	0.0	2	2	1
7	1	22.0	1.64	53.0	0	0	2.0	3.0	2	0	2.0	0	3.0	0.0	2	3	1
8	1	24.0	1.78	64.0	1	1	3.0	3.0	2	0	2.0	0	1.0	1.0	1	3	1
9	1	22.0	1.72	68.0	1	1	2.0	3.0	2	0	2.0	0	1.0	1.0	3	3	1

Gambar 3. Dataset setelah *Label Encoding*

b. Normalisasi Data

Dalam langkah normalisasi data, proses normalisasi dilakukan menggunakan rumus *Z Score*. Dengan rumus ini, setiap nilai diubah dengan mengurangi nilai rata-rata (*mean*) dan kemudian dibagi dengan standar deviasi.

Gender	Age	Height	Weight	family_history	FAVC	FCVC	NCP	CAEC	SMOKE	CH2O	SCC	FAF	TUE	CALC	HTRANS	
0	-1.011914	-0.522124	-0.875589	-0.862558	0.472291	-2.759769	-0.785019	0.404153	0.300346	-0.145900	-0.013073	-0.218272	-1.188039	0.561997	1.419172	0.503337
1	-1.011914	-0.522124	-1.947599	-1.168077	0.472291	-2.759769	1.088342	0.404153	0.300346	6.853997	1.618759	4.581439	2.339750	-1.080625	-0.521160	0.503337
2	0.988227	-0.206889	1.054029	-0.366090	0.472291	-2.759769	-0.785019	0.404153	0.300346	-0.145900	-0.013073	-0.218272	1.163820	0.561997	-2.461491	0.503337
3	0.988227	0.423582	1.054029	0.015808	-2.117337	-2.759769	1.088342	0.404153	0.300346	-0.145900	-0.013073	-0.218272	1.163820	-1.080625	-2.461491	1.296280
4	0.988227	-0.364507	0.839627	0.122740	-2.117337	-2.759769	-0.785019	0.404153	0.300346	-0.145900	-0.013073	-0.218272	-1.188039	-1.080625	-0.521160	0.503337
5	0.988227	0.738817	-0.875589	-1.282647	-2.117337	0.362349	-0.785019	0.404153	0.300346	-0.145900	-0.013073	-0.218272	-1.188039	-1.080625	-0.521160	-1.875493
6	-1.011914	-0.206889	-2.162001	-1.206267	0.472291	0.362349	1.088342	0.404153	0.300346	-0.145900	-0.013073	-0.218272	-0.012109	-1.080625	-0.521160	-0.289606
7	0.988227	-0.364507	-0.661187	-1.282647	-2.117337	-2.759769	-0.785019	0.404153	0.300346	-0.145900	-0.013073	-0.218272	2.339750	-1.080625	-0.521160	0.503337
8	0.988227	-0.049271	0.839627	-0.862558	0.472291	0.362349	1.088342	0.404153	0.300346	-0.145900	-0.013073	-0.218272	-0.012109	0.561997	-2.461491	0.503337
9	0.988227	-0.364507	0.196421	-0.709799	0.472291	0.362349	-0.785019	0.404153	0.300346	-0.145900	-0.013073	-0.218272	-0.012109	0.561997	1.419172	0.503337

Gambar 3. Dataset setelah normalisasi data

3. **Pemodelan Klasifikasi dan Optimasi**
 Setelah melakukan pembersihan data pada tahap preproses selanjutnya dilakukan penyusunan model klasifikasi menggunakan *Support Vector Machine* (SVM) dan optimasi Algoritma Genetika (GA). Berikut dibawah ini merupakan Langkah-langkah proses klasifikasi dan optimasi.
 - a. Menginisialisasi parameter Algoritma Genetika (GA) dan *Support Vector Machine* (SVM). Pada penelitian ini nilai parameter yang digunakan adalah jumlah generasi sebanyak 15 dengan ukuran populasi yang bervariasi. Ukuran populasi yang nantinya akan digunakan adalah 5, 10, dan 25. Selain kedua parameter diatas akan digunakan parameter default yaitu *crossover probability* sebesar 0.7, dan *mutation probability* sebesar 0.3. Sementara itu pada metode *Support Vector Machine* (SVM) terdapat 4 jenis kernel yang dapat dipilih. Pada penelitian ini digunakan tipe kernel linear dengan nilai parameter yang akan dioptimasi adalah nilai C dan gamma. Rentang nilai C dan gamma yang akan digunakan adalah 0-100 untuk keduanya.
 - b. Pembentukan populasi awal. Pada langkah ini nilai C dan gamma akan dikombinasikan secara acak menjadi individu baru. Individu akan terus dibentuk sebanyak jumlah populasi yang sebelumnya sudah ditentukan.
 - c. Melatih tiap individu. Tiap individu yang sudah dibentuk kemudian dilatih dengan menggunakan model SVM. Data tersebut dilatih dengan nilai C dan gamma yang sebelumnya sudah ditentukan.
 - d. Menghitung nilai *fitness* untuk setiap individu. Nilai *fitness* merupakan acuan dalam seberapa baik solusi yang diwakili oleh individu tersebut dalam mencapai tujuan optimisasi. Setelah melatih individu maka perlu dilakukan perhitungan nilai *fitness*. Pada penelitian ini nilai *fitness* berupa nilai akurasi.
 - e. Pengecekan kriteria. Pada Langkah ini dilakukan pengecekan kriteria berhenti. Jika sudah memenuhi maka algoritma genetika akan lanjut melakukan pengujian dengan SVM. Kriteria berhenti pada penelitian ini adalah jika jumlah generasi telah memenuhi jumlah yang sebelumnya diinisialisasi atau jika nilai *fitness* telah cukup konvergen.
 - f. Pemilihan induk. Jika kondisi berhenti belum terpenuhi maka akan dilakukan seleksi pemilihan induk. Induk akan dipilih berdasarkan nilai *fitness*-nya. Individu yang menghasilkan nilai *fitness* yang cukup tinggi ini akan digunakan sebagai induk.
 - g. Melakukan *crossover*. Setelah menentukan induknya maka selanjutnya adalah pembentukan individu baru dengan cara kawin silang. Proses ini

dilakukan pada setiap induk dengan berdasarkan probabilitas *crossover* yang sebelumnya sudah ditentukan.

- h. Melakukan mutasi. Mutasi dilakukan berdasarkan besarnya *mutation probability* yang sebelumnya sudah ditentukan pada inialisasi parameter. Individu anak yang sebelumnya sudah dibentuk kemudian akan dilakukan mutasi dengan menambahkan nilai acak yang sangat kecil sesuai dengan *mutation probability* agar dapat menemukan solusi baru yang lebih variatif.
- i. Terbentuk populasi baru. setelah melakukan *crossover* dan mutasi terbentuklah individu-individu baru sebanyak jumlah populasi yang ditentukan. Populasi baru ini nantinya akan dilakukan pelatihan lagi dan pencarian nilai *fitness* yang baru.
- j. Menemukan parameter terbaik. Jika kriteria berhenti telah dipenuhi maka kombinasi parameter terbaik akan ditentukan berdasarkan nilai *fitness* yang paling tinggi.
- k. Pengujian SVM. Dengan kombinasi parameter terbaik yang telah ditentukan maka dilakukan pengujian pada dataset uji menggunakan metode SVM.
- l. Melakukan evaluasi. Setelah menguji parameter terbaik yang dihasilkan selanjutnya adalah dengan mengevaluasi kinerja dari parameter tersebut. Evaluasi dilakukan menggunakan *confusion matrix* untuk mengukur akurasi, *precision*, *recall*, dan *F-1 Score*.

4. Skenario Pengujian

Setelah melakukan beberapa percobaan sesuai dengan skenario pengujian, perbandingan antara tiap skenario akan dilakukan pada bagian ini. Tujuan perbandingan ini adalah untuk mengevaluasi pengaruh metode optimasi Algoritma Genetika terhadap algoritma *Support Vector Machine* dalam klasifikasi obesitas.

Tabel 2. Hasil Pengujian

N o.	Metode	Populasi	Data Training	Data Testing	Akurasi	<i>Precision</i>	<i>recall</i>	<i>F1-Score</i>	Waktu
1	<i>Support Vector Machine</i>	-	90%	10%	88.7%	89%	87%	87%	0.01s
2			80%	20%	88.9%	89%	89%	89%	0.01s
3			70%	30%	87.4%	88%	87%	87%	0.01s
4	<i>Support Vector Machine</i>	-	90%	10%	95.8%	96%	96%	95%	0.01s
5			80%	20%	95.6%	95%	96%	95%	0.01s
6			70%	30%	94.8%	95%	95%	95%	0.01s
7	<i>Support</i>	5	90%	10%	97.2%	97%	96%	97%	87s

8	<i>Vector Machine</i>		80%	20%	97.6%	98%	97%	97%	85s
9		<i>Linear &</i>	70%	30%	97.2%	97%	97%	97%	54s
10	Algoritma Genetika	10	90%	10%	97.2%	97%	97%	97%	170s
11			80%	20%	97.9%	98%	98%	98%	129s
12			70%	30%	97.3%	97%	97%	97%	111s
13		25	90%	10%	97.2%	97%	96%	97%	404s
14			80%	20%	97.9%	98%	98%	98%	359s
15			70%	30%	97.3%	97%	97%	97%	262s

Berdasarkan tabel di atas, pengujian metode *Support Vector Machine* tanpa optimasi dilakukan pada skenario 1, 2, dan 3. Skenario 1, dengan pembagian data 90:10, mencapai akurasi 88.7%. Skenario 2, dengan pembagian 80:20, mencapai akurasi tertinggi di antara ketiga skenario ini dengan 88.9%. Skenario 3, dengan pembagian 70:30, menghasilkan akurasi terendah, yaitu 87.4%.

Selanjutnya, pengujian *Support Vector Machine Linear* tanpa optimasi dilakukan pada skenario 4, 5, dan 6. Skenario 4, dengan pembagian data 90:10, mencapai akurasi tertinggi di antara ketiganya dengan 95.8%. Skenario 5, dengan pembagian 80:20, menghasilkan akurasi 95.6%. Skenario 6, dengan pembagian 70:30, memperoleh akurasi terendah dengan 94.8%.

Pengujian *Support Vector Machine Linear* dengan optimasi Algoritma Genetika dilakukan pada skenario 7-15, dengan variasi jumlah populasi dan pembagian data. Pada skenario 7-9, yang menggunakan populasi 5, skenario 8 dengan pembagian data 80:20 mencapai akurasi tertinggi 97.6% dengan waktu pemrosesan 84 detik. Skenario 7 dengan pembagian 90:10 mencapai akurasi 97.17% dengan waktu pemrosesan 86 detik, dan skenario 9 dengan pembagian 70:30 mencapai akurasi 97.16% dengan waktu pemrosesan tercepat 54 detik.

Pada skenario 10-12, yang menggunakan populasi 10, skenario 11 dengan pembagian data 80:20 mencapai akurasi tertinggi 97.9% dengan waktu pemrosesan 129 detik. Skenario 12 dengan pembagian 70:30 mencapai akurasi 97.32% dengan waktu pemrosesan tercepat 111 detik, dan skenario 10 dengan pembagian 90:10 mencapai akurasi 97.17% dengan waktu pemrosesan 170 detik.

Skenario 13-15, yang menggunakan populasi 25, menunjukkan hasil akurasi yang mirip dengan skenario sebelumnya. Skenario 14 dengan pembagian data 80:20 mencapai akurasi tertinggi 97.9% dengan waktu pemrosesan 359 detik. Skenario 15 dengan pembagian 70:30 mencapai akurasi 97.32% dengan waktu pemrosesan tercepat 262 detik, dan skenario 13 dengan pembagian 90:10 mencapai akurasi 97.17% dengan waktu pemrosesan 404 detik.

Dari setiap skenario pengujian yang dilakukan, nilai akurasi model *Support Vector Machine Linear* dengan optimasi Algoritma Genetika mengalami peningkatan. Ini menunjukkan bahwa penerapan metode optimasi Algoritma Genetika mampu meningkatkan akurasi model *Support Vector Machine Linear*

dalam mengklasifikasikan obesitas. Nilai akurasi tertinggi, yaitu 97.9%, tercapai pada skenario 11 dan 14 dengan rasio pembagian data 80:20. Di antara keduanya, waktu pemrosesan tercepat adalah pada skenario 11, yaitu sekitar 129 detik.

KESIMPULAN

Metode optimasi algoritma genetika telah terbukti mampu meningkatkan hasil akurasi model *Support Vector Machine Linear* dalam mengklasifikasikan obesitas. Hasil akurasi tertinggi pengujian *Support Vector Machine* tanpa optimasi adalah 88.9% dengan rasio pembagian data 80:20. Kemudian hasil akurasi tertinggi pengujian *Support Vector Machine Linear* tanpa optimasi adalah 95.8% dengan rasio pembagian data 90:10. Dan yang terakhir akurasi tertinggi pengujian *Support Vector Machine Linear* dengan optimasi algoritma genetika adalah 97.9% dengan jumlah populasi sebesar 10 dan rasio pembagian data 80:20. Nilai parameter terbaik yang didapat adalah kombinasi nilai parameter $C = 66.82109849558405$ dan nilai $\gamma = 64.46895332656808$. Sementara itu waktu pemrosesan adalah sekitar 129.1 detik.

REFERENSI

- Moschonis, G., & Trakman, G. L. (2023). Overweight and Obesity: The Interplay of Eating Habits and Physical Activity. 3–6.
- Toro Lafia, A., Richard Ketounou, T., Nonvignon Bossis Honfoga, J., Ibrahim Bonou, S., & Kora Bani Zimé, A. (2022). Dietary habits, prevalence of obesity and overweight in developed and developing countries. 11. <http://dx.doi.org/10.33448/rsd-v11i10.32769>
- Octarine, S. W., & Mahmudiono, T. (2022). Apakah Kebiasaan Makan Berhubungan dengan Overweight/Obesitas pada Wanita Dewasa Indonesia? Berdasarkan Indonesian Family Life Survey (IFLS) 5 Tahun 2014. *Media Gizi Kemas*, 11(1), 176–178.
- Hidayatulloh, T., Yusuf, L., Bina, U., Informatika, S., Informasi, S., Nusa, U., Jakarta, M., & Informasi, S. (2023). Inti Nusa Mandiri Klasifikasi Tipe Berat Tubuh Menggunakan. 18(1), 71–77.
- Chatterjee, A., Gerdes, M. W., & Martinez, S. G. (2020). Identification of risk factors associated with obesity and overweight—a machine learning overview. *Sensors* (Switzerland), 20(9). <https://doi.org/10.3390/s20092734>
- Ramdhani, Y., Apra, D. F., & Alamsyah, D. P. (2023). Feature selection optimization based on genetic algorithm for support vector classification varieties of raisin. *Indonesian Journal of Electrical Engineering and Computer Science*, 30(1), 192–199. <https://doi.org/10.11591/ijeecs.v30.i1.pp192-199>
- Darmawan, I. P. D. W., Pradnyana, G. A., & Pascima, I. B. N. (2023). Optimasi Parameter Support Vector Machine Dengan Algoritma Genetika Untuk Analisis Sentimen Pada Media Sosial Instagram. *SINTECH (Science and Information Technology) Journal*, 6(1), 58–67. <https://doi.org/10.31598/sintechjournal.v6i1.1245>