

KLASIFIKASI DEPRESI MENGGUNAKAN SUPPORT VECTOR MACHINE: PENDEKATAN BERBASIS DATA TEXT MINING

Firman Aziz¹, Pertiwi Ishak^{2*}, Sustrin Abasa³

Program Studi Ilmu Komputer, Universitas Pancasakti, Makassar¹

Program Studi Farmasi, Universitas Pancasakti, Makassar^{2,3}

Email Korespondensi Author: pertiwi.ishak@unpacti.ac.id

Kata kunci:

Deteksi depresi, Klasifikasi, Machine Learning, SVM, Kesehatan Mental.

Abstrak

Deteksi dini depresi merupakan tantangan penting dalam bidang kesehatan mental. Depresi merupakan gangguan mental serius yang berdampak signifikan pada fungsi sosial dan pekerjaan, serta meningkatkan risiko kondisi kesehatan. Penelitian ini bertujuan untuk mengembangkan model klasifikasi yang dapat memprediksi depresi dengan tingkat akurasi tinggi menggunakan teknik klasifikasi data. Data kuesioner digunakan sebagai dasar untuk pengembangan model ini. Melalui proses pembersihan data, ekstraksi fitur, dan normalisasi, data disiapkan untuk pelatihan dan pengujian model. Pembagian data dilakukan dengan proporsi 80:20 antara data pelatihan dan data pengujian. K-fold cross-validation digunakan untuk memastikan generalisasi model. Selanjutnya, parameter SVM dioptimalkan menggunakan grid search dan cross-validation. Model dilatih dan dievaluasi menggunakan metrik evaluasi yang mencakup akurasi, presisi, recall, dan F1-Score. Hasil penelitian menunjukkan bahwa model klasifikasi depresi mencapai tingkat keakuratan, presisi, recall, dan F1-Score sebesar 100%. Implikasi hasil ini dalam praktik klinis dibahas, bersama dengan rekomendasi untuk penelitian lebih lanjut. Kesimpulannya, penelitian ini menunjukkan potensi besar dalam pengembangan model klasifikasi depresi yang akurat dan andal untuk meningkatkan deteksi dini dan intervensi depresi.

Keywords:

Depression detection, Classification, Machine Learning, SVM, Mental Health.

Abstrack

Early detection of depression poses a significant challenge in the field of mental health. Depression is a serious mental disorder that has a significant impact on social and occupational functioning, and increases the risk of health conditions. This research aims to develop a classification model capable of predicting depression with high accuracy using data classification techniques. Questionnaire data serves as the basis for model development. Through data cleaning, feature extraction, and normalization processes, the data is prepared for model training and testing. Data is divided into training and testing sets in an 80:20 ratio. K-fold cross-validation is employed to ensure model generalization. Furthermore, SVM parameters are optimized using grid search and cross-validation. The model is trained and evaluated using evaluation metrics including accuracy, precision, recall, and F1-Score. Results indicate that the depression classification model achieves accuracy, precision, recall, and F1-Score rates of 100%. Implications of these findings in clinical practice are discussed alongside recommendations for further research. In conclusion, this study demonstrates significant potential in developing accurate and reliable depression classification models to enhance early detection and intervention for depression.

Pendahuluan

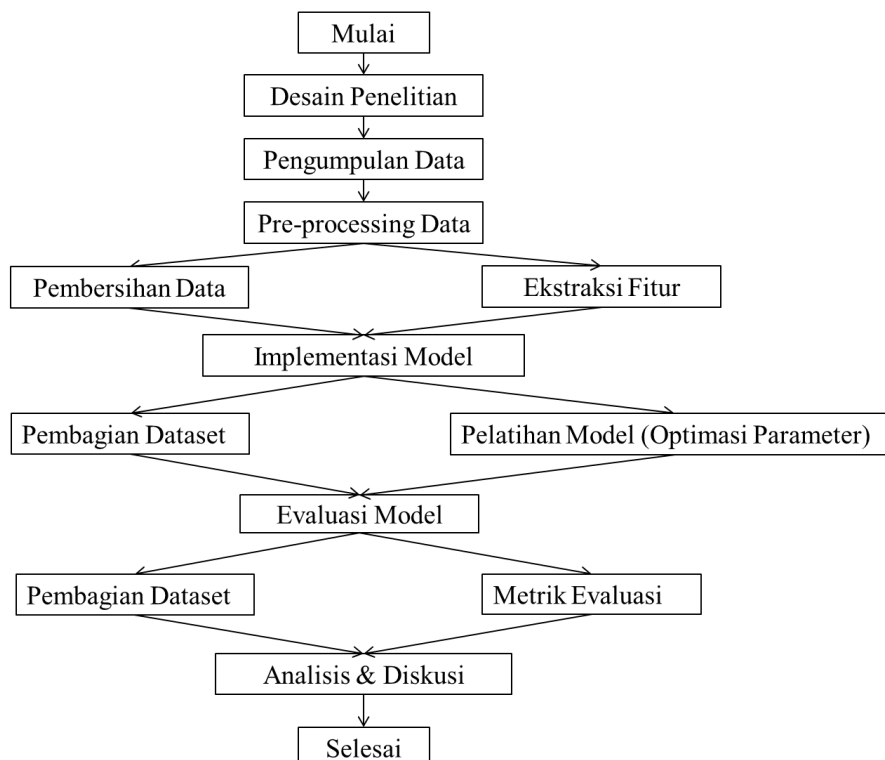
Depresi merupakan gangguan mental serius yang mempengaruhi lebih dari 264 juta orang di seluruh dunia, menurut data dari World Health Organization (WHO). Gangguan ini tidak hanya menyebabkan perasaan sedih yang berkepanjangan (Wijayati et al., 2024), tetapi juga berdampak signifikan pada fungsi sosial dan pekerjaan, serta meningkatkan risiko kondisi kesehatan lainnya (Puspitasari et al., 2019). Identifikasi dan intervensi dini sangat penting untuk mengelola depresi secara efektif dan mencegah konsekuensi yang lebih serius. Namun, tantangan utama dalam deteksi depresi adalah banyaknya kasus yang tidak terdiagnosis atau terlambat terdiagnosis, sering kali disebabkan oleh stigma sosial, kurangnya kesadaran individu, dan keterbatasan dalam akses layanan kesehatan mental (Untuk D Salah et al., 2024). Kuesioner seperti Beck Depression Inventory (BDI), Patient Health Questionnaire-9 (PHQ-9), dan Hamilton Depression Rating Scale (HDRS) merupakan alat yang umum digunakan untuk mendeteksi gejala depresi (Budhi, 2024). Meskipun kuesioner ini dapat diandalkan,

analisis manual data kuesioner memerlukan waktu dan sumber daya yang signifikan, sehingga diperlukan pendekatan otomatis untuk meningkatkan efisiensi dan akurasi deteksi depresi (Zebua et al., 2023).

Metode Support Vector Machine (SVM) adalah salah satu algoritma machine learning yang terkenal karena kinerjanya yang kuat dalam klasifikasi. SVM efektif dalam menangani data yang kompleks dan mampu memisahkan kelas dengan margin yang optimal. Dalam konteks klasifikasi depresi, SVM dapat digunakan untuk mengidentifikasi pola-pola dalam data kuesioner yang menunjukkan adanya depresi. Namun, ada beberapa masalah utama yang perlu diatasi dalam penelitian ini. Pertama, kualitas data kuesioner sering kali mengandung kebisingan dan informasi yang tidak lengkap, sehingga perlu dilakukan pra-pemrosesan yang tepat untuk meningkatkan kualitas data. Kedua, identifikasi fitur yang relevan dari data kuesioner untuk digunakan dalam model SVM merupakan tantangan tersendiri. Fitur-fitur ini harus dapat merepresentasikan gejala depresi secara akurat. Ketiga, menentukan parameter yang optimal untuk SVM guna meningkatkan akurasi dan kinerja model dalam klasifikasi depresi adalah aspek penting lainnya. Terakhir, evaluasi kinerja model secara menyeluruh dengan menggunakan metrik evaluasi yang komprehensif, seperti akurasi, presisi, recall, dan F1-score, sangat diperlukan untuk memastikan model yang dihasilkan dapat diandalkan (F Aziz, 2021; Firman Aziz, 2020; N Hardiyanti & Lawi, A, 2022.; Nurul Hardiyanti et al., 2018; Lawi et al., 2019).

Penelitian ini bertujuan untuk mengembangkan model klasifikasi depresi menggunakan metode Support Vector Machine dengan pendekatan berbasis data kuesioner. Dengan mengumpulkan dan mempersiapkan dataset kuesioner yang relevan, mengimplementasikan SVM untuk klasifikasi, serta mengevaluasi kinerja model, diharapkan penelitian ini dapat memberikan kontribusi signifikan dalam bidang deteksi dini depresi. Penelitian ini juga diharapkan dapat meningkatkan efisiensi deteksi depresi dengan menggunakan pendekatan otomatis berbasis machine learning, meningkatkan akurasi diagnosis depresi dibandingkan dengan metode manual, serta menyediakan alat bantu yang berguna bagi profesional kesehatan mental dalam mendukung diagnosis dan intervensi lebih awal. Dengan demikian, penelitian ini tidak hanya berkontribusi pada pengembangan ilmu pengetahuan di bidang kesehatan mental dan teknologi informasi, tetapi juga memberikan dampak positif terhadap kesejahteraan individu yang menderita depresi.

Metode



Gambar 1. Alur penelitian

Desain Penelitian

Penelitian ini menggunakan desain studi kuantitatif dengan pendekatan machine learning untuk mengembangkan model klasifikasi depresi. Data yang digunakan dalam penelitian ini adalah data kuesioner yang mengukur gejala depresi.

Pemilihan Data dan Sumber Data

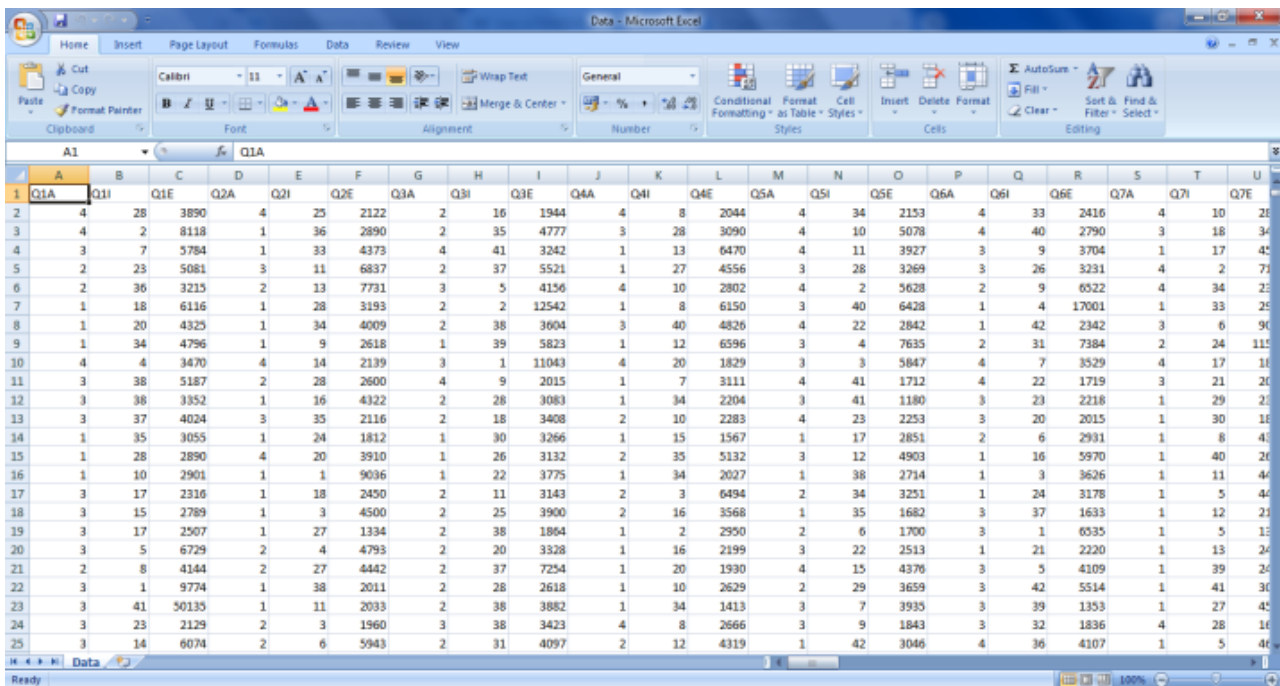
pengumpulan data dari berbagai sumber dari survei yang dilakukan dari tahun 2017 sampai 2019. Dataset mencakup informasi yang cukup terstruktur dan relevan untuk klasifikasi depresi dengan kriteria sebagai berikut:

- Q1 : Saya merasa kesal karena hal-hal sepele.
- Q2 : Saya menyadari mulut saya kering.
- Q3 : Sepertinya saya tidak merasakan perasaan positif sama sekali.
- Q4 : Saya mengalami kesulitan bernapas (misalnya napas terlalu cepat, sesak napas tanpa adanya aktivitas fisik).
- Q5 : Sepertinya saya tidak bisa berangkat.
- Q6 : Saya cenderung bereaksi berlebihan terhadap situasi.
- Q7 : Saya merasa gemetar (misalnya, kaki terasa lemas).
- Q8 : Saya merasa sulit untuk bersantai.
- Q9 : Saya mendapati diri saya berada dalam situasi yang membuat saya sangat cemas sehingga saya merasa sangat lega ketika situasi itu berakhir.
- Q10 : Saya merasa tidak ada lagi yang bisa diharapkan.
- Q11 : Saya mendapati diri saya mudah marah.
- Q12 : Saya merasa menggunakan banyak energi gugup.
- Q13 : Saya merasa sedih dan depresi.
- Q14 : Saya menjadi tidak sabar ketika saya mengalami keterlambatan dalam hal apa pun (misalnya, lift, lampu lalu lintas, terus menunggu).
- Q15 : Saya merasa pingsan.
- Q16 : Saya merasa kehilangan minat pada segala hal.
- Q17 : Saya merasa saya tidak berharga sebagai manusia.
- Q18 : Aku merasa aku agak sensitif.
- Q19 : Saya banyak berkeringat (misalnya tangan berkeringat) tanpa suhu tinggi atau aktivitas fisik.
- Q20 : Saya merasa takut tanpa alasan yang jelas.
- Q21 : Saya merasa hidup ini tidak berharga.
- Q22 : Saya merasa sulit untuk bersantai.
- Q23 : Saya kesulitan menelan.
- Q24 : Sepertinya saya tidak mendapatkan kesenangan apa pun dari apa yang saya lakukan.
- Q25 : Saya menyadari tindakan jantung saya ketika tidak ada aktivitas fisik (misalnya, detak jantung terasa meningkat, jantung tidak berdetak).
- Q26 : Saya merasa sedih dan sedih.
- Q27 : Saya menemukan bahwa saya sangat mudah tersinggung.
- Q28 : Saya merasa hampir panik.
- Q29 : Saya merasa sulit untuk tenang setelah ada sesuatu yang membuat saya kesal.
- Q30 : Saya takut bahwa saya akan dilempar oleh beberapa tugas sepele tapi asing.
- Q31 : Saya tidak bisa merasa antusias terhadap apa pun.
- Q32 : Saya merasa sulit menoleransi interupsi terhadap apa yang sedang saya lakukan.
- Q33 : Saya berada dalam keadaan tegang.
- Q34 : Saya merasa saya tidak berharga.
- Q35 : Saya tidak toleran terhadap apa pun yang menghalangi saya untuk melanjutkan pekerjaan saya.
- Q36 : Saya merasa ketakutan.
- Q37 : Saya tidak melihat apa pun di masa depan yang bisa saya harapkan.
- Q38 : Saya merasa hidup ini tidak ada artinya.
- Q39 : Saya merasa gelisah.

- Q40 : Saya khawatir dengan situasi yang mungkin membuat saya panik dan memperlakukan diri sendiri.
- Q41 : Saya mengalami gemetar (misalnya di tangan).
- Q42 : Saya merasa sulit untuk meningkatkan inisiatif dalam melakukan sesuatu.

Pre-processing Data

Pada tahap pembersihan data, langkah-langkah yang dilakukan mencakup penghapusan respon yang tidak lengkap atau tidak valid serta penanganan data yang hilang dengan menggunakan metode imputasi jika memungkinkan. Selanjutnya, dalam proses ekstraksi fitur, data kuesioner dikonversi ke dalam format yang dapat dianalisis, seperti skala Likert pada setiap item kuesioner. Fitur yang diekstraksi mencakup skor total kuesioner beserta subskala jika ada. Kemudian, pada tahap normalisasi data, dilakukan proses normalisasi untuk memastikan bahwa semua fitur berada dalam skala yang sama, yang merupakan langkah penting untuk meningkatkan kinerja SVM.



	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U
1	Q1A	Q1I	Q1E	Q2A	Q2I	Q2E	Q3A	Q3I	Q3E	Q4A	Q4I	Q4E	Q5A	Q5I	Q5E	Q6A	Q6I	Q6E	Q7A	Q7I	Q7E
2	4	28	3890	4	25	2122	2	16	1944	4	8	2044	4	34	2153	4	33	2416	4	10	28
3	4	2	8118	1	36	2890	2	35	4777	3	28	3090	4	10	5078	4	40	2790	3	18	34
4	3	7	5784	1	33	4373	4	41	3242	1	13	6470	4	11	3927	3	9	3704	1	17	42
5	2	23	5081	3	11	6837	2	37	5521	1	27	4556	3	28	3269	3	26	3231	4	2	71
6	2	36	3215	2	13	7731	3	5	4156	4	10	2802	4	2	5628	2	9	6522	4	34	25
7	1	18	6116	1	28	3193	2	2	12542	1	8	6150	3	40	6428	1	4	17001	1	33	29
8	1	20	4325	1	34	4009	2	38	3604	3	40	4826	4	22	2842	1	42	2342	3	6	90
9	1	34	4796	1	9	2618	1	39	5823	1	12	6596	3	4	7635	2	31	7384	2	24	111
10	4	4	3470	4	14	2139	3	1	11043	4	20	1829	3	3	5847	4	7	3529	4	17	11
11	3	38	5187	2	28	2600	4	9	2015	1	7	3111	4	41	1712	4	22	1719	3	21	20
12	3	38	3352	1	16	4322	2	28	3083	1	34	2204	3	41	1180	3	23	2218	1	29	25
13	3	37	4024	3	35	2116	2	18	3408	2	10	2283	4	23	2253	3	20	2015	1	30	18
14	1	35	3055	1	24	1812	1	30	3266	1	15	1567	1	17	2851	2	6	2931	1	8	43
15	1	28	2890	4	20	3910	1	26	3132	2	35	5132	3	12	4903	1	16	5970	1	40	20
16	1	10	2901	1	1	9036	1	22	3775	1	34	2027	1	38	2714	1	3	3626	1	11	44
17	3	17	2316	1	18	2450	2	11	3143	2	3	6494	2	34	3251	1	24	3178	1	5	44
18	3	15	2789	1	3	4500	2	25	3900	2	16	3568	1	35	1682	3	37	1633	1	12	23
19	3	17	2507	1	27	1334	2	38	1864	1	2	2950	2	6	1700	3	1	6035	1	5	13
20	3	5	6729	2	4	4793	2	20	3328	1	16	2199	3	22	2513	1	21	2220	1	13	24
21	2	8	4144	2	27	4442	2	37	7254	1	20	1930	4	15	4376	3	5	4109	1	39	24
22	3	1	9774	1	38	2011	2	28	2618	1	10	2629	2	29	3659	3	42	5514	1	41	30
23	3	41	50135	1	11	2033	2	38	3882	1	34	1413	3	7	3935	3	39	1353	1	27	42
24	3	23	2129	2	3	1960	3	38	3423	4	8	2666	3	9	1843	3	32	1836	4	28	16
25	3	14	6074	2	6	5943	2	31	4097	2	12	4319	1	42	3046	4	36	4107	1	5	44

Gambar 2. Dataset

Implementasi Model

Dalam tahap implementasi model, data dibagi menjadi dua set, yaitu data pelatihan (training set) dan data pengujian (testing set) dengan proporsi 80:20. Untuk memastikan model tidak overfitting, digunakan metode k-fold cross-validation. Selanjutnya, dalam pemilihan parameter SVM, seperti kernel (linear, polynomial, RBF) dan parameter regulasi, dilakukan optimisasi menggunakan grid search dan cross-validation. Setelah parameter optimal ditemukan, dilakukan pelatihan model SVM menggunakan data pelatihan yang telah diproses. Kernel yang dipilih bersama dengan parameter yang dioptimalkan digunakan dalam proses pelatihan model.

Evaluasi Model

Dalam tahap evaluasi model, dilakukan pengukuran menggunakan beberapa metrik evaluasi yang mencakup akurasi, presisi, recall (sensitivitas), dan F1-Score. Akurasi mengukur persentase prediksi yang benar dari total prediksi, sementara presisi mengukur ketepatan antara prediksi positif dengan hasil yang benar-benar positif. Recall mengukur kemampuan model dalam mendeteksi kasus depresi yang benar-benar ada, sedangkan F1-Score memberikan gambaran seimbang mengenai kinerja model dengan mengambil harmonis rata-rata dari presisi dan recall. Setelah mendefinisikan metrik evaluasi, model diuji menggunakan data pengujian yang telah dipisahkan sebelumnya. Metrik evaluasi kemudian dihitung untuk menilai kinerja model pada data pengujian, memberikan pemahaman yang komprehensif tentang seberapa baik model dapat memprediksi kasus depresi.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$\text{F1 Score} = 2 \times \frac{\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}}$$

Analisis dan Diskusi

Dalam analisis dan interpretasi data, hasil dari metrik evaluasi model dibandingkan dengan hasil dari model lain atau dengan baseline yang ada, memberikan pemahaman tentang keunggulan dan kelemahan model dalam klasifikasi depresi. Performa model dianalisis secara mendalam untuk memahami sejauh mana model dapat memprediksi kasus depresi dengan akurat. Hasil model kemudian diinterpretasikan dalam konteks klinis untuk memastikan bahwa model dapat digunakan sebagai alat bantu yang berguna dalam proses diagnosa depresi. Diskusi mengenai implikasi hasil penelitian terhadap praktik klinis dilakukan, serta potensi penerapan model dalam skala yang lebih luas dan saran untuk penelitian lebih lanjut. Dengan pendekatan ini, diharapkan penelitian ini dapat menghasilkan model klasifikasi depresi yang akurat dan andal, memberikan kontribusi yang signifikan dalam bidang deteksi dini depresi, serta membantu dalam pengembangan intervensi yang lebih efektif.

Hasil dan Diskusi

Dalam penelitian ini, model klasifikasi depresi telah mencapai hasil yang luar biasa dengan nilai akurasi, F1-Score, presisi, dan recall sebesar 100%. Hasil ini menandakan bahwa model dapat mengidentifikasi dan mengklasifikasikan individu dengan depresi atau tanpa depresi dengan sempurna. Keberhasilan ini memberikan harapan baru dalam upaya deteksi dini depresi dan peningkatan akses terhadap perawatan yang tepat.

Dalam konteks klinis, keakuratan model ini dapat mengubah cara diagnosis depresi dilakukan. Dengan tingkat keakuratan yang sangat tinggi, model ini dapat digunakan sebagai alat bantu dalam praktik klinis untuk membantu profesional kesehatan mental dalam membuat keputusan yang lebih tepat dan akurat. Ini dapat mengarah pada peningkatan efisiensi dalam proses diagnosa, pengurangan kesalahan diagnosa, dan pengurangan waktu antara deteksi dan intervensi.

Selain itu, hasil ini memiliki implikasi yang signifikan dalam hal pengembangan intervensi yang lebih efektif. Dengan kemampuan model untuk mengidentifikasi individu dengan depresi secara akurat, intervensi dapat dilakukan lebih awal, yang dapat mengurangi risiko komplikasi yang berkaitan dengan depresi dan meningkatkan prognosis pasien. Hal ini dapat membantu mengurangi beban penyakit yang terkait dengan depresi secara keseluruhan.

Namun, perlu diingat bahwa meskipun hasil yang diperoleh sangat mengesankan, penelitian lebih lanjut diperlukan untuk memvalidasi dan menguji model ini dalam berbagai populasi dan konteks klinis yang berbeda. Evaluasi lanjutan terhadap faktor-faktor seperti keragaman demografis, kultural, dan lingkungan juga penting untuk memastikan bahwa model ini dapat digunakan secara luas dan dapat diandalkan di berbagai setting.

Dengan demikian, hasil ini menunjukkan potensi besar dalam penggunaan model klasifikasi depresi dalam praktik klinis, tetapi penelitian dan pengembangan lebih lanjut diperlukan untuk memastikan bahwa model ini dapat memberikan manfaat maksimal bagi individu yang membutuhkan.

Kesimpulan

Dalam penelitian ini, kami menyelidiki masalah deteksi dini depresi menggunakan teknik klasifikasi data. Masalah ini penting karena depresi merupakan salah satu gangguan mental yang umum dan sering kali tidak terdiagnosis dengan baik, terutama pada tahap awal. Penelitian ini bertujuan untuk mengembangkan model klasifikasi yang dapat secara akurat mengidentifikasi tanda-tanda depresi pada

individu berdasarkan data kuesioner atau informasi lain yang dapat diakses secara elektronik. Dalam penelitian ini, sebuah model klasifikasi depresi telah dikembangkan dengan hasil yang sangat mengesankan, mencapai nilai akurasi, F1-Score, presisi, dan recall sebesar 100%. Hasil ini menandakan bahwa model mampu dengan sempurna membedakan antara individu yang mengalami depresi dan yang tidak dengan tingkat keakuratan yang sangat tinggi. Implikasi dari hasil ini dalam konteks klinis sangat penting, di mana model ini dapat menjadi alat yang sangat berharga bagi profesional kesehatan mental dalam membantu proses diagnosa depresi dengan memberikan arahan yang jelas dalam perencanaan intervensi yang tepat. Meskipun demikian, penting untuk dicatat bahwa penelitian dan pengujian lebih lanjut diperlukan untuk memvalidasi kehandalan model ini dalam berbagai konteks klinis dan populasi yang berbeda. Dengan demikian, penelitian ini menunjukkan potensi besar dalam pengembangan model klasifikasi depresi yang sangat akurat dan andal, yang dapat memberikan kontribusi signifikan dalam meningkatkan deteksi dini depresi dan akses terhadap perawatan yang sesuai bagi individu yang membutuhkan.

Referensi

- Aziz, F. (2021). Klasifikasi Aktivitas Manusia menggunakan metode Ensemble Stacking berbasis Smartphone. *Journal.Unpacti.Ac.Id*, 1(2), 53. <http://journal.unpacti.ac.id/index.php/JSCE/article/view/171>
- Aziz, Firman. (2020). Klasifikasi Pelanggan Deposito Potensial menggunakan Ensembel Least Square Support Vector Machine. *Journal of System and Computer Engineering*, 1(1), 1. <http://journal.unpacti.ac.id/index.php/JSCE/article/view/80>
- Budhi, B. (2024). KEEFEKTIFAN ANALISIS TRANSAKSIONAL FOKUS SKRIP PASIEN DEPRESI PRAJURIT, SUATU PENDEKATAN MIXED METHOD.
- Hardiyanti, N, & Lawi, A, F. A. (n.d.). Classification of human activity based on sensor accelerometer and gyroscope using ensemble SVM method. *Ieeexplore.Ieee.Org*, 2018. Retrieved June 15, 2022, from <https://ieeexplore.ieee.org/abstract/document/8878627/>
- Hardiyanti, Nurul, Lawi, A., Diaraya, & Aziz, F. (2018). Classification of Human Activity based on Sensor Accelerometer and Gyroscope Using Ensemble SVM method. *Proceedings - 2nd East Indonesia Conference on Computer and Information Technology: Internet of Things for Industry, EICONCIT 2018*, 304–307. <https://doi.org/10.1109/EICONCIT.2018.8878627>
- Lawi, A., Idris Rifai Sarro, M., & Aziz, F. (2019). Classification of Firm External Audit Using Ensemble Support Vector Machine Method. <https://doi.org/10.4108/eai.2-5-2019.2284605>
- Puspitasari, C. E., Andayani, T. M., & Irijanto, F. (2019). Pengaruh Keselamatan dan Kesehatan Kerja serta Beban Kerja terhadap Kinerja Pekerja Proyek Konstruksi. *Ejurnal.Politeknikpratama.Ac.Id*, 9(3), 182–191. <https://doi.org/10.22146/jmpf.43187>
- Untuk, D., Salah, M., Syarat, S., Gelar, M., Keperawatan, S., Keperawatan, J., Kedokteran, F., Ilmu, D., Uin, K., Makassar, A., & Sari, M. (n.d.). Analisis Kejadian Depresi dan Risiko Bunuh Diri menggunakan Buddy App pada Remaja di Wilayah Kota Makassar. *Core.Ac.Uk*. Retrieved June 12, 2024, from <https://core.ac.uk/download/pdf/198227062.pdf>
- Wijayati, F., Nasir, T., Hadi, I., Keperawatan, J., Kemenkes Kendari, P., & Mandala Waluya, Stik. (n.d.). Faktor-faktor yang berhubungan dengan kejadian harga diri rendah pasien gangguan jiwa. *Myjurnal.Poltekkes-Kdi.Ac.Id*. Retrieved June 7, 2024, from <https://myjurnal.poltekkes-kdi.ac.id/index.php/HIJP/article/view/234>
- Zebua, R., Khairunnisa, K., Hartatik, H., & Pariyadi, P. (2023). Fenomena Artificial Intelligence (Ai).