

Komparasi Metode *Machine Learning* pada Diagnosa Gangguan Kejiwaan Depresi

Rusda Wajhillah¹, Saeful Bahri², Agung Wibowo³

^{1,3}Universitas Bina Sarana Informatika Kampus Sukabumi, Indonesia

²STMIK Nusa Mandiri Jakarta, 43111, Indonesia

Jl. Cemerlang. No. 8 Sukakarya Sukabumi

Email: ¹rusda.rwh@bsi.ac.id ²saeful.sel@nusamandiri.ac.id, ³agung.awo@bsi.ac.id

Abstrak. Depresi atau penyakit kejiwaan berakibat fatal pada resiko kemungkinan bunuh diri. Depresi dapat didiagnosa sejak dini dan dilakukan secara mandiri. Hal ini sangat perlu dilakukan untuk membantu dalam penyembuhan dan pencegahan depresi. Model yang tepat dalam mendiagnosa depresi secara mandiri telah banyak diusulkan oleh beberapa peneliti. Pada penelitian ini dibandingkan metode machine learning yang paling akurat untuk mendiagnosa depresi, diantaranya algoritma Naïve bayes, KNN, Decision Tree dan Random Forest. Hasilnya diketahui algoritma Random Forest memiliki nilai akurasi paling tinggi diantara tiga algoritma lainnya yaitu sebesar 80,02%.

Kata kunci: komparasi, machine learning, depresi.

1 Pendahuluan

Depresi adalah penyakit kejiwaan yang diderita lebih dari 300 juta orang di dunia, 96% penyebab bunuh diri adalah depresi, tercatat 800.000 orang mati setiap harinya akibat bunuh diri. Bunuh diri merupakan faktor kedua terbesar penyebab kematian orang dengan rentang usia 15-29 tahun setelah kecelakaan lalulintas [1].

Diagnosa gangguan kejiwaan depresi perlu dilakukan sejak dini dan secara mandiri [2] [3], karena diagnosa dini dan mandiri dalam diagnosa gangguan kejiwaan depresi sangat penting untuk membantu dalam penyembuhan dan pencegahan depresi [4].

Model diagnosa mandiri dengan machine learning (ML) [2], [3], [5]–[8] telah banyak diusulkan oleh beberapa peneliti di dunia.

Kelebihan model diagnosa mandiri dibandingkan dengan machine learning adalah bahwa machine learning dapat menangani keputusan yang rumit yang tidak dapat dilakukan oleh psikiatri, onkologi, kardiologi, dan dokter seperti penentuan prediktor resistensi pengobatan atau perencanaan pengobatan [9]. Akan tetapi ML memiliki kelemahan pada jenis dataset dan model yang digunakan sehingga akan terpengaruh pada diagnosa yang dihasilkan [9].

Komparasi Metode Machine Learning pada Diagnosa ...

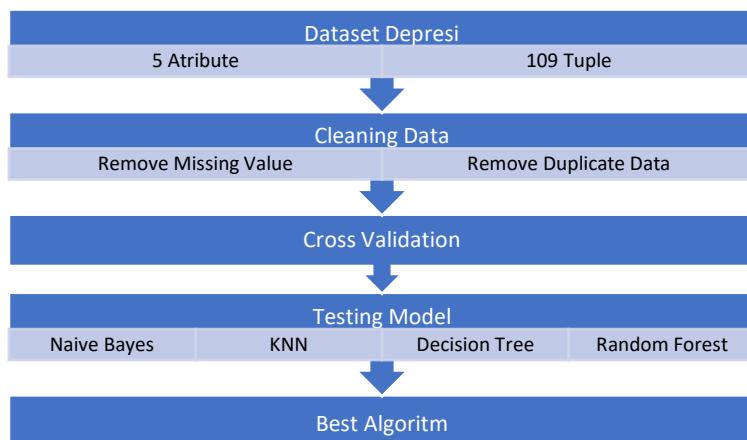
Machine learning dapat mengurangi dimensi dari banyak variable yang tidak dapat diuraikan untuk menjadi objek prediksi dalam diagnosa gangguan kejiwaan depresi [6]. Sehingga machine learning lebih tepat digunakan untuk diagnosa mandiri gangguan kejiwaan depresi. Namun demikian, machine learning itu sendiri memiliki banyak metode dengan karakteristik yang berbeda sehingga tidak semua algoritma yang ada dalam ML dapat digunakan untuk melakukan diagnosa depresi.

Pada penelitian ini akan dibandingkan beberapa metode yang ada dalam machine learning untuk menemukan metode terbaik yang digunakan untuk diagnosa gangguan kejiwaan depresi. Perbandingan metode yang ada pada ML dapat menemukan metode terbaik dalam melakukan diagnosis gangguan depresi.

2 Metode Penelitian

2.1 Kerangka Penelitian

Metodologi yang diusulkan pada penelitian ini adalah dengan membandingkan empat algoritma machine learning, diantaranya Naïve Bayes, KNN, Decision Tree dan Random Forest. Kerangka penelitian yang diusulkan dapat dilihat pada Gambar 1.



Gambar 1. Kerangka Penelitian

Kerangka pada penelitian ini menggambarkan tahapan demi tahapan dimulai dari pemilihan dataset yang menggunakan dataset depression dari situs kaggle.com, dimana dataset terdiri dari lima atribut dan 109 baris data. Pada tahap awal dataset difilter dengan cara menghapus baris data yang tidak lengkap (missing) dan data ganda. Dataset tersebut akan diujikan menggunakan empat metode

populer di machine learning (Naïve Bayes, KNN, Decision Tree dan Random Forest) dengan uji validitas menggunakan 10-fold Cross validation. Hasil uji validitas dijadikan kriteria algoritma terbaik untuk pengenalan depresi.

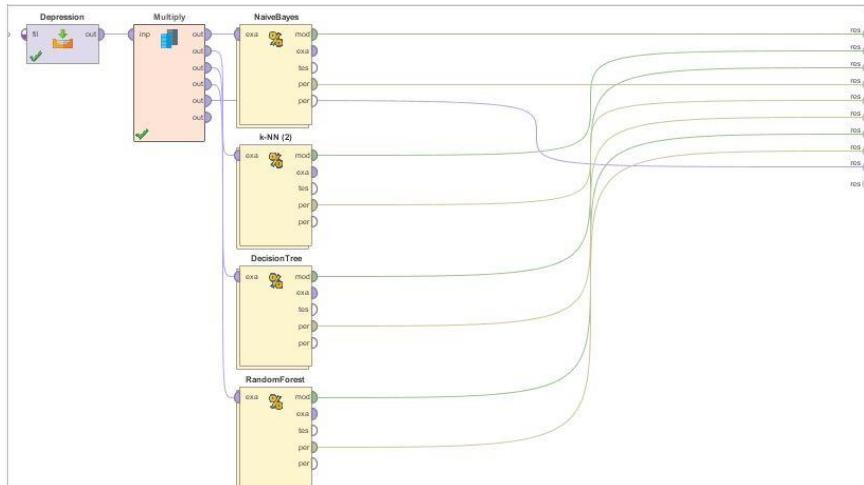
2.2 Data Collection

Data yang digunakan pada penelitian ini menggunakan data yang public yang bersumber dari <https://www.kaggle.com/everseek/depression> dengan jumlah atribut sebanyak lima atribut yaitu: treat, time, acute, age, gender dan sebuah label outcome. Sample yang digunakan sebanyak 109 tuple secara random.

3 Hasil dan Pembahasan

3.1 Model Komparasi

Metode machine learning yang digunakan pada penelitian ini diantaranya algoritma Naïve-Bayes, KNN, Decision Tree dan Random Forest. Untuk memperoleh nilai akurasi berdasar empat metode klasifikasi, menggunakan data yang sama.



Gambar 2. Komparasi Model Menggunakan Rapidminer

Pada penelitian ini dilakukan komparasi empat algoritma machine learning diantaranya Naïve-Bayes, KNN, Decission Tree, dan Random Forest.

3.2 Kasus Naïve Bayes

Tabel 1. Nilai Prediksi Algoritma Naive Bayes

	NILAI SEBENARNYA

Komparasi Metode Machine Learning pada Diagnosa ...

Nilai Prediksi		TRUE	FALSE
	TRUE	47	17
	FALSE	10	35

$$\text{Nprecision} = \frac{47}{47+17} = \frac{47}{64} = 0,73$$

$$\text{Nreccal} = \frac{47}{47+10} = \frac{47}{57} = 0,82$$

$$\text{Naccuracy} = \frac{47+35}{47+35+17+10} = \frac{82}{109} = 0,75$$

3.3 Kasus KNN

Tabel 2. Nilai Prediksi Algoritma KNN

NILAI SEBENARNYA			
Nilai Prediksi		TRUE	FALSE
	TRUE	42	12
	FALSE	15	40

$$\text{KNNprecision} = \frac{42}{42+12} = \frac{42}{54} = 0,77$$

$$\text{KNNreccal} = \frac{42}{42+15} = \frac{42}{57} = 0,73$$

$$\text{KNNAccuracy} = \frac{42+40}{42+40+12+15} = \frac{82}{109} = 0,75$$

3.4 Kasus Decission Tree

Tabel 3. Nilai Prediksi Algoritma Decision Tree

NILAI SEBENARNYA			
Nilai Prediksi		TRUE	FALSE
	TRUE	46	15
	FALSE	11	37

$$\text{DTprecision} = \frac{46}{46+15} = \frac{46}{61} = 0,75$$

$$\text{DTreccal} = \frac{46}{46+11} = \frac{46}{57} = 0,80$$

$$\text{DTAccuracy} = \frac{46+37}{46+37+15+11} = \frac{83}{109} = 0,76$$

3.5 Kasus Random Forest

Tabel 4. Nilai Prediksi Algoritma Random Forest

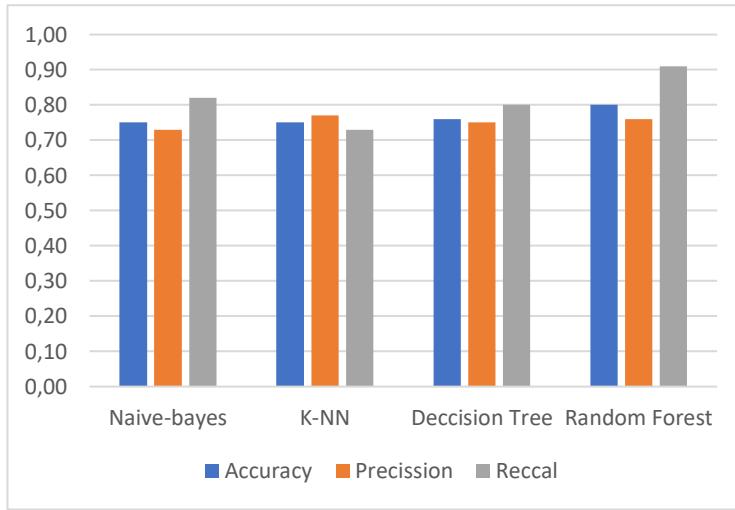
NILAI SEBENARNYA			
Nilai Prediksi		TRUE	FALSE
	TRUE	52	16
	FALSE	5	36

$$\text{RFprecision} = \frac{52}{52+16} = \frac{52}{68} = 0,76$$

$$\text{RFreccal} = \frac{52}{52+5} = \frac{52}{57} = 0,91$$

$$\text{RFAccuracy} = \frac{52+36}{52+36+16+5} = \frac{88}{109} = 0,80$$

Berdasarkan pengujian empat model machine learning, dapat dilihat rekap nilai akurasi, presisi dan reccal masing-masing algoritma seperti Gambar 3 di bawah ini.



Gambar 3. Perbandingan Akurasi N-B, K-NN, Decission Tree, Random Forest

4 Kesimpulan

Hasil pengujian empat algoritma machine learning menunjukkan nilai akurasi Algoritma Random Forest sebesar 80,02%. Nilai akurasi tersebut masih dapat ditingkatkan dengan memanfaatkan optimasi algoritma tersebut.

Dataset yang digunakan pada penelitian ini masih berupa dataset yang bersifat publik sehingga validitas dari dataset yang digunakan masih perlu pendalaman untuk mendapatkan hasil yang valid juga, akan lebih baik apabila dataset yang digunakan adalah dataset yang telah teruji validitasnya namun pada penelitian ini kami tidak hanya terfokus pada dataset yang digunakan akan tetapi kepada hasil yang didapatkan dari pengujian beberapa algoritma yang akan digunakan untuk mendiagnosa gangguan kejiwaan deprsesi, dari hasil pengujian ini didapat bahwa algoritma Random Forest memiliki nilai akurasi tertinggi yaitu sebesar 0,80%, jadi dapat disimpulkan bahwa hasil klasifikasi dari dataset yang digunakan sangat baik bila menggunakan random forest. Untuk penelitian selanjutnya, algoritma

terbaik dapat dioptimasi agar diperoleh akurasi yang lebih tinggi. Dataset penelitian yang digunakan dapat dioptimalkan esemble algorithm.

5 Acknowledgements

Terimakasih kepada rekan-rekan penelitian Universitas Bina Sarana Informatika.

6 Referensi

- [1] WHO, “Depresion,” 22 March 2018, 2019. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/depression>.
- [2] A. Sau and I. Bhakta, “Screening of anxiety and depression among the seafarers using machine learning technology,” *Informatics Med. Unlocked*, no. October, p. 100149, 2018.
- [3] B. Besteher, C. Gaser, and I. Nenadić, “Machine-learning based brain age estimation in major depression showing no evidence of accelerated aging,” *Psychiatry Res. - Neuroimaging*, vol. 290, no. January, pp. 1–4, 2019.
- [4] S. G. Burdisso, M. Errecalde, and M. Montes-y-Gómez, “A text classification framework for simple and effective early depression detection over social media streams,” *Expert Syst. Appl.*, vol. 133, pp. 182–197, 2019.
- [5] E. Y. Kim, M. Y. Lee, S. H. Kim, K. Ha, K. P. Kim, and Y. M. Ahn, “Diagnosis of major depressive disorder by combining multimodal information from heart rate dynamics and serum proteomics using machine-learning algorithm,” *Prog. Neuropsychopharmacology Biol. Psychiatry*, vol. 76, pp. 65–71, 2017.
- [6] J. F. Dipnall *et al.*, “Why so GLUMM? Detecting depression clusters through graphing lifestyle-environs using machine-learning methods (GLUMM),” *Eur. Psychiatry*, vol. 39, pp. 40–50, 2017.
- [7] O. Tymofiyeva *et al.*, “Application of machine learning to structural connectome to predict symptom reduction in depressed adolescents with cognitive behavioral therapy (CBT),” *NeuroImage Clin.*, vol. 23, no. July, p. 101914, 2019.
- [8] X. Li *et al.*, “Depression recognition using machine learning methods with different feature generation strategies,” *Artif. Intell. Med.*, 2019.
- [9] A. Pigoni, G. Delvecchio, D. Madonna, C. Bressi, J. Soares, and P. Brambilla, “Can Machine Learning help us in dealing with treatment resistant depression? A review,” *J. Affect. Disord.*, vol. 259, no. August, pp. 21–26, 2019.