

ALGORITMA K-NEAREST NEIGHBOR (K-NN) DAN SINGLE LAYER PERCEPTRON (SLP) UNTUK KLASIFIKASI PENYAKIT ALZHEIMER

Novi Rustiana Dewi^{1*}, Anita Desiani², Fitri Salamah³, Yuli Andriani⁴

^{1,2,3,4} Matematika dan Ilmu Pengetahuan Alam, Universitas Sriwijaya, Indralaya, Indonesia
E-mail: ^{1*}novirustiana@unsri.ac.id, ²anita_desiani@unsri.ac.id,
³08011182025003@student.unsri.ac.id, ⁴yuliandriani@unsri.ac.id

Abstrak

Penyakit Alzheimer adalah gangguan otak yang menyebabkan hilangnya daya ingat, penurunan kemampuan berpikir, kesulitan berkomunikasi, dan perubahan perilaku. Deteksi dini penyakit ini sangat penting untuk pengobatan yang tepat dan perencanaan kebutuhan medis. Namun, saat ini belum ada obat yang dapat menyembuhkan Alzheimer. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan prediksi dini yang akurat untuk penyakit Alzheimer dengan membandingkan dua algoritma: K-Nearest Neighbor (KNN) dan Single Layer Perceptron (SLP) menggunakan metode percentage split. Hasil penelitian menunjukkan bahwa pengujian menggunakan algoritma K-NN menghasilkan akurasi sebesar 96%. Nilai presisi dan recall untuk kelas 0 (Nondemented) berturut-turut adalah 93% dan 100%, sedangkan untuk kelas 1 (Demented) adalah 100% dan 91%. Di sisi lain, pengujian menggunakan algoritma SLP menghasilkan akurasi sebesar 99%. Nilai presisi dan recall untuk kelas 0 (Nondemented) berturut-turut adalah 97% dan 100%, sedangkan untuk kelas 1 (Demented) adalah 100% dan 98%. Berdasarkan perbandingan nilai akurasi, presisi, dan recall, serta performansi kedua metode klasifikasi, dapat disimpulkan bahwa implementasi algoritma Single Layer Perceptron memberikan prediksi terbaik untuk deteksi dini penyakit Alzheimer. Penemuan ini memberikan potensi penggunaan algoritma ini dalam memfasilitasi diagnosis awal dan intervensi tepat waktu bagi pasien dengan Alzheimer.

Kata Kunci: Alzheimer, K-Nearest Neighbor, Single Layer Perceptron, Klasifikasi

Abstract

Alzheimer's disease is a brain disorder that causes memory loss, decreased thinking skills, communication difficulties, and behavioral changes. Early detection of this disease is very important for proper treatment and planning of medical needs. However, there is currently no drug that can cure Alzheimer's. Therefore, this study aims to develop accurate early predictions for Alzheimer's disease by comparing two algorithms: K-Nearest Neighbor (KNN) and Single Layer Perceptron (SLP) using the percentage split method. The results showed that testing using the K-NN algorithm resulted in an accuracy of 96%. The precision and recall values for class 0 (nondemented) are 93% and 100%, respectively, while for class 1 (demented) are 100% and 91%. On the other hand, testing using the SLP algorithm produces an accuracy of 99%. The precision and recall values for class 0 (nondemented) are 97% and 100% respectively, while for class 1 (demented) are 100% and 98%. Based on a comparison of the values for accuracy, precision, and recall, as well as the performance of the two classification methods, it can be concluded that the implementation of the Single Layer Perceptron algorithm provides the best prediction for early detection of Alzheimer's disease. These findings provide potential use of this algorithm in facilitating early diagnosis and timely intervention for patients with Alzheimer's.

Keywords: Alzheimer, K-Nearest Neighbor, Single Layer Perceptron, Classification

I. PENDAHULUAN

Alzheimer adalah penyakit yang menyebabkan penurunan daya ingat yang terjadi pada orang tua, dimana penyakit ini akan menyerang sistem saraf otak yang bisa menyebabkan hilangnya sel neuron dan menyebabkan penderita sulit melakukan kegiatan sehari-hari karena kebingungan untuk mencerna pertanyaan, ingatan

yang berantakan, dan berujung kehilangan kemampuan untuk mengingat (Wildah et al., 2020). Penyebab ataupun faktor yg mengakibatkan seorang menderita penyakit Alzheimer biasa faktor usia. Penyakit Alzheimer didiagnosis dalam usia 65 tahun atau lebih tua. Akan tetapi, Orang muda kurang dari usia 65

tahun juga bisa terkena penyakit ini, meskipun hal ini jauh lebih jarang sehingga usia merupakan faktor risiko terbesar. Selanjutnya, riwayat keluarga dan trauma cedera otak sedang atau berat akan menaikkan risiko perkembangan penyakit Alzheimer. Organisasi Kesehatan Dunia (WHO) mengungkapkan bahwa 55 juta penduduk dunia mengalami penurunan daya ingat dan cara berpikir yang kini bisa menjangkiti orang berusia 30 sampai 40 tahun. Dan akan diperkirakan penderita demensia akan meningkat pada tahun 2030 mencapai 78 juta dan mencapai 139 penderita pada tahun 2050 (Aulia, 2021). Dari data penyakit Alzheimer akan terjadi peningkatan sehingga deteksi dini pada penyakit Alzheimer sangat diperlukan.

Deteksi dini penyakit Alzheimer dapat dilakukan dengan menggunakan metode penyelesaian matematika, yaitu pendekatan data mining. *Data mining* merupakan sekumpulan proses untuk menggali nilai dalam bentuk pengetahuan yang sebelumnya tidak diketahui secara manual dari suatu kumpulan data (Yuli Mardi, 2019). Dalam penelitian ini akan digunakan dua algoritma, yaitu *K-Nearest Neighbor* (K-NN) dan *Single Layer Perceptron* (SLP). *K-Nearest Neighbor* (K-NN) adalah suatu metode untuk mengklasifikasikan objek berdasarkan data training yang jaraknya paling dekat dengan objek tersebut (Safaat et al., 2020). Sedangkan, *Single Layer Perceptron* merupakan jenis jaringan saraf yang paling sederhana terdiri dari satu lapisan yang terdiri atas satu lapisan input dan satu lapisan output (Muhammad Varriel Avenazh Nizar et al., 2022). Dari dua algoritma yang akan digunakan terdapat kelebihan dan kekurangan masing-masing.

Algoritma K-NN memiliki beberapa kelebihan, yaitu tangguh terhadap training data yang noise dan efektif apabila data training besar (Rismala et al., 2023). Kekurangan K-NN, yaitu pada pemilihan nilai K dalam K-NN yang perlu mempertimbangkan ukuran data, apabila ukuran data terlalu kecil maka dimensi data dan variasi jarak dalam tabel jarak antara data latih menjadi lebih kecil sehingga peluang suatu data uji dikenali masuk ke kelas lain menjadi lebih besar (Sa'dan et al., 2019). SLP memiliki keunggulan dalam kemampuannya untuk memperoleh pengetahuan tanpa memerlukan tingkat keakuratan yang tinggi pada data yang digunakan. Selain itu, algoritma ini mampu menggeneralisasi dan mengekstraksi pola dari data tertentu. Melalui penyesuaian diri atau kemampuan belajar, algoritma SLP dapat menghasilkan pola

pengetahuan yang relevan. Dengan demikian, algoritma SLP memiliki kelebihan dalam menangani data yang tidak lengkap atau tidak akurat, serta mampu menghasilkan pengetahuan yang berharga dalam berbagai aplikasi. (Mada Abdillah, 2017). Salah satu kekurangan dari *Single Layer Perceptron* (SLP) adalah keterbatasannya dalam menyelesaikan masalah dengan lebih dari dua kelas data. Performanya cenderung kurang baik ketika dihadapkan pada data yang memiliki lebih dari dua kelas. Dalam konteks ini, kinerja SLP tidak optimal dan mungkin mengalami kesulitan dalam mengklasifikasikan data dengan akurasi yang tinggi. Hal ini membatasi penggunaan SLP pada tugas-tugas yang melibatkan data dengan banyak kelas atau klasifikasi yang kompleks. (Najwa et al., 2017).

Berdasarkan kelebihan dan kekurangan yang dimiliki oleh algoritma K-NN dan SLP, pada penelitian ini akan membandingkan hasil implementasi K-NN dan SLP dalam mendeteksi penyakit Alzheimer dan ingin membandingkan kinerja algoritma terbaik untuk mendeteksi penyakit Alzheimer dari perspektif *unsupervised learning* (K-NN) dan *supervised learning* (SLP). Pada penelitian ini juga akan didapatkan nilai akurasi, presisi dari algoritma K-NN dan SLP. Dan pada algoritma K-NN akan didapatkan nilai tetangga terbaik dan pada SLP akan didapatkan nilai epoch terbaik. Hasil penelitian akan dievaluasi berdasarkan nilai akurasi, presisi, dan recall yang diperoleh dari kedua algoritma. Akurasi akan menunjukkan sejauh mana algoritma dapat mengklasifikasikan pasien dengan benar. Presisi akan memberikan informasi tentang proporsi pasien yang benar terdiagnosis sebagai positif penyakit Alzheimer dari keseluruhan pasien yang terdiagnosis positif. Recall akan memberikan informasi tentang proporsi pasien yang benar terdiagnosis sebagai positif penyakit Alzheimer dari keseluruhan pasien yang sebenarnya menderita penyakit tersebut (Istighfarizky et al., 2022). Diharapkan bahwa penelitian ini akan memberikan wawasan yang berharga tentang kinerja dan efektivitas kedua algoritma dalam mendeteksi penyakit Alzheimer. Dengan mengetahui algoritma terbaik, akan memungkinkan pengembangan sistem deteksi dini yang lebih akurat dan efisien untuk penyakit Alzheimer. Hasil penelitian ini dapat memberikan kontribusi signifikan dalam bidang perawatan dan manajemen penyakit Alzheimer, dengan potensi untuk meningkatkan

perencanaan medis yang tepat dan intervensi dini bagi pasien.

II. METODE PENELITIAN

A. Deskripsi Data

Deskripsi data yang digunakan dalam penelitian ini yaitu dataset yang diperoleh dari situs kaggle (<https://www.kaggle.com/datasets/brsdincer/Alzheimer-features>) dengan format csv. Data terkait penyakit alzheimer tersebut berjumlah 373 data. Dataset Alzheimer yang memiliki 10 atribut, 9 diantaranya sebagai atribut prediksi yaitu *Gender*, *Age*, *Educ*, *SES*, *MMSE*,

CDR, *eTiv*, *nWBV*, dan *ASF*. Sedangkan atribut target yaitu *Group*, yaitu *demented*, *nondemented*, dan *converted*. Akan tetapi kelas *converted* dikategorikan ke dalam kelas *demented* (Wildah et al., 2020). Dapat dikatakan bahwa *nondemented* (0) dan *demented* (1) sehingga *converted* kita gabungkan dengan kelas *Demented*. Sehingga, jumlah data *Demented* sebanyak 183 dan *Nondemented* sebanyak 190. Atribut dan informasi data yang digunakan pada artikel ini disajikan pada Tabel 1.

Tabel 1. Atribut dan Informasi Data

Atribut	Keterangan atribut	Data Kosong
<i>Group</i>	0 : <i>Non-demented</i> 1 : <i>Demented</i> 2 : <i>Converted</i>	Null
<i>Gender</i>	0 : <i>Male</i> 1 : <i>Female</i>	Null
<i>Age</i>	Usia subjek pada saat dilakukan pemeriksaan. (60 tahun – 98 tahun)	Null
<i>EDUC</i>	Tingkat Pendidikan. (6-23)	Null
<i>SES</i>	Status Sosial Ekonomi. 1(<i>highest statue</i>)-5 (<i>lowest statue</i>).	19
<i>MMSE</i>	Nilai pemeriksaan keadaan mental. 0 (<i>worst value</i>) - 30 (<i>best value</i>).	2
<i>CDR</i>	Tingkat demensia klinis. (0 : <i>No Dementia</i> , 0.5 : <i>Very Mild AD</i> , 1 : <i>Mild AD</i> , 2 : <i>Moderate AD</i>).	Null
<i>eTIV</i>	Perkiraan total volume intracranial. (1106-2004)	Null
<i>nWBV</i>	Volume keseluruhan otak yang dinormalisasikan di eksersika dengan persentase dari semua voxel. (0.644-0.837)	Null
<i>ASF</i>	Faktor Skala Atlas; faktor penskalaan volume untuk ukuran otak. (0.837-1.587)	Null

B. Praproses Data

a. Missing Value

Missing value merupakan sebuah kondisi di mana beberapa nilai atribut dalam dataset kosong atau tidak terdefinisi, menjadi tantangan dalam analisis data. *Missing value* dapat diatasi dengan beberapa teknik yang efektif, yaitu mengganti missing value dengan menggunakan mean atau modus (Ilham, 2020). Pada dataset Alzheimer dari Tabel 1 bahwa terdapat 2 atribut yang memiliki data kosong, yaitu pada kolom *SES* sebanyak 19 record dan pada kolom *MMSE* sebanyak 2 record, maka untuk mengatasi data kosong dilakukan pengisian data kosong. Pada kolom *SES* dilakukan pengisian data dengan modus, dimana dilihat nilai terbanyak muncul dari keseluruhan data pada kolom *SES*. Dan pada kolom *MMSE* dilakukan pengisian data kosong dengan mean, dimana akan dilihat nilai rata-rata keseluruhan dari data pada kolom *MMSE*.

b. Standarisasi Data

Pada dataset Alzheimer dari Tabel 1 terlihat bahwa atribut *MMSE* dan atribut *eTIV*

memiliki rentang nilai yang cukup jauh sehingga dilakukan standarisasi data. Standarisasi data dilakukan untuk menghindari salah satu atribut yang mendominasi. Pada penelitian ini metode standarisasi data menggunakan Min-Max Normalization dengan Persamaan (1) berikut (Nasution et al., 2019).

$$S = \frac{\min Range x + (x - \min Value)(\max Range - \min Range)}{\max Value - \min Value} \quad (1)$$

C. Percentage Split

Percentage split merupakan metode pengambilan sampel ulang, dimana dataset keseluruhan dibagi menjadi dua bagian yakni data training dan data testing. Persentase yang dimasukkan akan digunakan untuk proses training dan sisanya akan digunakan untuk proses testing (Sartika and Sensuse, 2017). Proses ini biasanya dilakukan dengan perbandingan 2/3 dari data yang digunakan untuk training dan 1/3 dari data yang digunakan untuk testing (Akbar and Rahmadden, 2022). Pada penelitian akan digunakan data training sebesar 80% dan data testing sebesar

20%. Sehingga didapatkan data training sebanyak 298 data dan data testing sebanyak 75 data.

D. K-Nearest Neighbor (K-NN)

K-Nearest Neighbor (K-NN) merupakan metode untuk melakukan klasifikasi terhadap objek baru berdasarkan nilai (K) tetangga terdekatnya. Langkah-langkah untuk menghitung algoritma KNN sebagai berikut (Febriana et al., 2021).

1. Menentukan nilai k, yaitu melihat nilai tetangga yang mirip dengan data yang di cek labelnya;
2. Menghitung kuadrat jarak *Euclidean* masing-masing objek terhadap *training data* yang diberikan. Rumus jarak euclidean terdapat pada Persamaan (2) berikut (Kurnia et al., 2019);

$$d(x, y) = \sqrt{\sum_{i=0}^n (x_i - y_i)^2} \quad (2)$$

Keterangan:

$d(x, y)$: Jarak *Euclidean*

x : Data 1

y : Data 2


i : Index Fitur

n : Index Fitur

3. Mengurutkan objek-objek tersebut ke dalam kelompok yang mempunyai jarak *Euclidean* terkecil;
4. Menentukan data yang akan diprediksi adalah kelompok data yang memiliki jumlah k pertama dari kumpulan data terbesar;
5. Menetapkan kelas terdekat dengan titik pertimbangan.

E. Single Layer Perceptron (SLP)

Single Layer Perceptron atau SLP adalah salah satu jenis arsitektur dari jaringan syaraf tiruan dimana hanya memiliki satu lapisan dengan bobot terhubung. Jaringan ini menerima masukan kemudian secara langsung akan mengelolanya menjadi keluaran tanpa harus melalui lapisan tersembunyi (Agung Riansa et al., 2019). Algoritma ini terdiri atas nilai input, lapisan input, pembobotan, lapisan output, dan nilai output seperti Gambar 1.



Gambar 1. Arsitektur Single Layer Perceptron

Untuk menentukan nilai error pada metode SLP ini maka digunakan fungsi aktivitas *sigmoid*. Langkah-langkah dalam algoritma SLP sebagai berikut (Mada Abdillah, 2017).

1. Pada penelitian ini, digunakan nilai learning rate (α) sebesar 0.3 dan threshold θ sebesar 0. Inisialisasi nilai bobot dan bias dapat dilakukan dengan dua pendekatan yang berbeda, yaitu:
 - a. Inisialisasi nilai bobot dan bias dengan nilai 0: Dalam pendekatan ini, semua bobot dan bias awal diatur dengan nilai 0. Hal ini berarti model awal memiliki bobot dan bias yang sama untuk semua fitur.
 - b. Inisialisasi nilai bobot dan bias secara acak: Dalam pendekatan ini, bobot dan bias awal diatur dengan nilai acak. Metode ini memberikan fleksibilitas lebih dalam memulai model dengan variasi bobot dan

bias awal yang berbeda-beda.

2. Mengatur aktivitasi untuk vector masukan

$$x = s^{(q)} \quad (3)$$

3. Menghitung respon untuk unit *output*:

$$y_{in} = \sum x_q \cdot w_q + b \quad (4)$$

4. Menghitung nilai keluaran:

$$y = f(y_{in}) = \frac{1}{1 + e^{-y_{in}}} \quad (5)$$

$$t = c - y \quad (6)$$

5. Jika klasifikasi sesuai atau $y \neq t$ atau nilai $t = \theta$ pada langkah 5, maka kondisi berhenti akan bernilai 'benar', namun kondisi akan bernilai 'salah' jika nilai $t = \theta$ sehingga dilakukan perbaikan bobot dan bias pola jika terjadi kesalahan:

$$w_{baru} = w_{lama} + \alpha \cdot t^{(q)} \cdot x \quad (7)$$

$$b_{baru} = b + \alpha \cdot t^{(q)} \quad (8)$$

6. Ulangi langkah-langkah 2-6 saat pengulangan dengan batasan nilai epoch k sampai proses

tersebut menghasilkan nilai kelas yang tepat.

F. Analisis Hasil

Confusion Matrix merupakan sebuah matriks yang menampilkan visualisasi kinerja dari algoritma klasifikasi menggunakan data dalam

matriks yang membandingkan klasifikasi prediksi dalam bentuk *True Positif* (TP), *False Positif* (FP), *True Negatif* (TN), dan *False Negatif* (FN) (Fansyuri, 2020). *Confusion matrix* dapat dilihat pada Tabel 2.

Tabel 2. Tabel Confusion Matrix

		Prediction	
		Negative	Positive
Actual	Negative	True Negative (TN)	False Positive (FP)
	Positive	False Negative (FN)	True Positive (TP)

True positive menunjukkan data positif yang diklasifikasikan sebagai positif dan *false positive* diklasifikasikan sebagai negatif. Sementara *true negative* menunjukkan data negatif yang diklasifikasikan sebagai negatif dan *false negative* diklasifikasikan sebagai positif (Pratama et al., 2019). Dari hasil *confusion matrix* dapat diukur kinerja metode yang digunakan dalam penelitian ini dengan menggunakan akurasi, presisi, dan *recall*.

a. Akurasi

Akurasi atau tingkat kesalahan merupakan angka prediksi yang benar atau salah yang dibuat oleh model melalui kumpulan dari data. Akurasi biasanya dihitung dengan menggunakan tes independen yang tidak selalu digunakan dalam proses pembelajaran.

Untuk menghitung nilai akurasi digunakan Persamaan (9) berikut (Baharuddin et al., 2019):

$$Akurasi = \frac{TP+TN}{TP+TN+FN+FP} \tag{9}$$

b. Presisi

Presisi merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang diprediksi positif. Persamaan (10) digunakan untuk menghitung nilai presisi (Baharuddin et al., 2019).

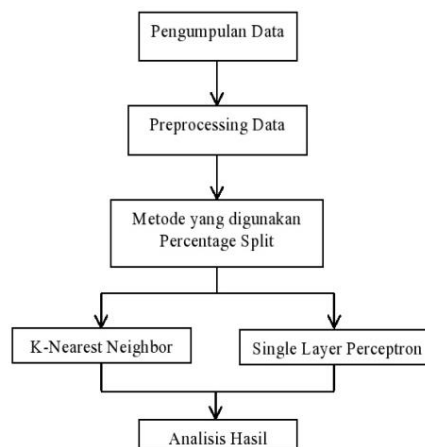
$$Presisi = \frac{TP}{TP+FP} \tag{10}$$

c. Recall

Recall atau sensitifitas merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan data yang benar positif. Nilai *recall* dapat dihitung dengan menggunakan persamaan (11) di bawah ini (Baharuddin et al., 2019).

$$Recall = \frac{TP}{TP+FN} \tag{11}$$

Hasil yang didapatkan oleh pengujian menggunakan algoritma K-NN dan SLP akan dibandingkan untuk mengetahui algoritma mana yang memiliki keakuratan lebih baik dalam menciptakan model terbaik. Secara umum, alur metode yang digunakan dalam penelitian ini dapat dilihat pada Gambar 2.



Gambar 2. Metode yang Digunakan dalam Artikel

III. HASIL DAN PEMBAHASAN

A. Hasil

1. *K-Nearest Neighbor* (KNN)

Pada algoritma ini, diperlukan pemilihan nilai K yang merupakan tetangga terdekat dari label yang digunakan. Pada data Alzheimer akan digunakan nilai K=1 sampai K=9 untuk menentukan K terbaik. Selanjutnya, dicari nilai akurasi, presisi, dan recall dari nilai K=1 sampai nilai K=9. Dengan mencari nilai K dari K=1 sampai K=9, kita dapat melihat perubahan dalam performa model K-NN seiring peningkatan

jumlah tetangga terdekat. Hal ini membantu kita untuk memahami bagaimana perubahan ini mempengaruhi akurasi, presisi, dan recall model, sehingga kita dapat memilih nilai K yang memberikan hasil terbaik dalam mendeteksi penyakit Alzheimer. Nilai akurasi, presisi dan recall akan dibandingkan dari setiap K=1 sampai K=2 dan akan didapatkan nilai K terbaik. Dari langkah-langkah tersebut akan didapatkan nilai precision, recall, dan akurasi setiap nilai K yang diinginkan terlihat seperti Tabel 3.

Tabel 3. Hasil Algoritma K-Nearest Neighbor

K	Target Class	Percentage Split		
		Precision	Recall	Akurasi
1	0	91%	100%	95%
	1	100%	89%	
2	0	80%	100%	89%
	1	100%	81%	
3	0	90%	100%	93%
	1	100%	82%	
4	0	85%	100%	91%
	1	100%	80%	
5	0	93%	100%	96%
	1	100%	91%	
6	0	89%	100%	93%
	1	100%	85%	
7	0	83%	100%	89%
	1	100%	78%	
8	0	93%	98%	95%
	1	97%	90%	
9	0	85%	100%	92%
	1	100%	86%	

Dalam Tabel 3, terdapat nilai akurasi, presisi, dan recall yang dihitung untuk setiap parameter K dalam algoritma K-Nearest Neighbor (K-NN). Nilai akurasi mengukur sejauh mana model dapat mengklasifikasikan data dengan benar secara keseluruhan. Pada Tabel 3, misalnya, pada parameter K=1, akurasi sebesar 95% berarti model berhasil mengklasifikasikan 95% data dengan benar. Nilai presisi mengukur sejauh mana model dapat mengidentifikasi secara tepat kasus positif dari hasil prediksi yang positif. Dalam hal ini, presisi pada kelas 0 (Nondemented) menggambarkan seberapa baik model dapat mengidentifikasi pasien yang tidak menderita penyakit Alzheimer dengan benar. Misalnya, pada K=5, nilai presisi sebesar 93% berarti model dapat mengidentifikasi 93% pasien yang sebenarnya tidak menderita penyakit Alzheimer dengan benar. Nilai recall (juga dikenal sebagai sensitivitas) mengukur sejauh mana model dapat mengidentifikasi secara tepat


kasus positif dari total kasus yang sebenarnya positif. Pada kelas 0 (Nondemented), recall menggambarkan seberapa baik model dapat mengidentifikasi pasien yang sebenarnya tidak menderita penyakit Alzheimer. Misalnya, pada K=1, recall sebesar 100% berarti model dapat mengidentifikasi semua pasien yang sebenarnya tidak menderita penyakit Alzheimer.

2. *Single Layer Perceptron*

Pada penelitian ini, digunakan beberapa parameter untuk melatih model perceptron pada dataset Alzheimer. Nilai learning rate (α) diatur sebesar 0.3, threshold θ diatur sebesar 0, dan semua bobot serta bias awal diatur dengan nilai 0. Selanjutnya, dilakukan pelatihan dengan menggunakan 50 epoch. Proses pelatihan dimulai dengan menghitung nilai masukan dan keluaran berulang kali hingga nilai keluaran yang diperoleh sama dengan nilai keluaran yang diharapkan. Jika nilai keluaran yang diperoleh

sudah sama dengan nilai keluaran yang diharapkan, kondisi berhenti tercapai. Namun, jika nilai keluaran yang diperoleh masih berbeda dengan nilai keluaran yang diharapkan, dilakukan

perbaikan pada bobot dan bias. Dari proses training, akan dihitung perbandingan *average loss* dengan nilai per epoch seperti Gambar 3.



Gambar 3. Hasil Training Single Layer Perceptron

Dari Gambar 3 bahwa nilai average loss mengalami stabilitas setelah beberapa epoch. Hal ini menunjukkan bahwa model perceptron telah mencapai hasil training yang optimal dan iterasi berhenti pada epoch 11. Pada penelitian ini, iterasi berhenti sebelum mencapai jumlah iterasi maksimum karena sudah menemukan solusi yang dapat memisahkan data pelatihan dengan sempurna dalam 11 epoch tersebut. Pada proses ini, model perceptron akan memberikan prediksi akhir, dan kemudian dilakukan perhitungan untuk mengukur akurasi model tersebut. Akurasi merupakan metrik yang menggambarkan sejauh mana model dapat memprediksi dengan benar. Hasil akurasi ini akan memberikan gambaran tentang seberapa baik model perceptron dapat mengklasifikasikan data. Dari data yang sudah dimodelkan akan didapatkan nilai akurasi, presisi dan recall terlihat pada Tabel 4.

Tabel 4. Hasil Pemodelan Algoritma SLP


Group	Accuracy	Precision	Recall
0	99%	97%	100%
1		100%	98%

Dari Tabel 4 menunjukkan hasil evaluasi performa model pada tahap pengujian menggunakan dataset Alzheimer. Evaluasi dilakukan dengan menghitung nilai presisi (*precision*), recall, dan jumlah data yang mendukung untuk setiap kelas. Pada kelas 0, model memiliki presisi sebesar 97%, yang berarti sebagian besar data yang diklasifikasikan sebagai kelas 0 benar-benar termasuk ke dalam kelas tersebut. Selain itu, recall untuk kelas 0 adalah 100%, yang menunjukkan bahwa model mampu

mengidentifikasi sebagian besar data yang sebenarnya termasuk dalam kelas 0. Terdapat 34 data yang mendukung kelas 0 dalam pengujian ini. Pada kelas 1, model memiliki presisi sebesar 100%, yang berarti sebagian besar data yang diklasifikasikan sebagai kelas 1 benar-benar termasuk ke dalam kelas tersebut. Selain itu, recall untuk kelas 1 adalah 98%, yang menunjukkan bahwa model mampu mengidentifikasi sebagian besar data yang sebenarnya termasuk dalam kelas 1. Terdapat 41 data yang mendukung kelas 1 dalam pengujian ini. Dari hasil evaluasi ini, dapat disimpulkan bahwa model memiliki performa yang sangat baik dalam mengklasifikasikan data Alzheimer. Akurasi model mencapai 99%, yang menunjukkan bahwa sebagian besar data pengujian berhasil diklasifikasikan dengan benar. Dapat disimpulkan bahwa hasil evaluasi ini mengindikasikan bahwa model Perceptron yang telah dilatih pada dataset Alzheimer memberikan prediksi yang akurat dan dapat diandalkan dalam mengklasifikasikan kasus Alzheimer.

B. Analisis Data

Setelah melalui implementasi algoritma K-Nearest Neighbor (K-NN) dan Single Layer Perceptron (SLP) pada dataset yang digunakan, hasil penelitian menunjukkan bahwa algoritma K-NN memberikan hasil terbaik dengan menggunakan metode percentage split. Perbandingan nilai akurasi, presisi, dan recall disajikan pada Gambar 4.



Gambar 4. Hasil Evaluasi

Berdasarkan Gambar 4, algoritma K-Nearest Neighbor (KNN) memberikan akurasi sebesar 96%. Akurasi merupakan ukuran yang mengindikasikan seberapa baik model dapat mengklasifikasikan data dengan benar secara keseluruhan. Dalam hal ini, algoritma KNN berhasil mengklasifikasikan 96% data dengan benar. Pada kelas 0 (Nondemented), algoritma KNN memiliki presisi sebesar 93%, yang berarti 93% dari data yang diprediksi sebagai kelas 0 adalah benar-benar kelas 0. Sementara itu, recall pada kelas 0 adalah 100%, yang berarti model berhasil menemukan semua data kelas 0 yang sebenarnya. Pada kelas 1 (Demented), algoritma KNN memiliki presisi sebesar 100%, yang berarti semua data yang diprediksi sebagai kelas 1 adalah benar-benar kelas 1. Recall pada kelas 1 adalah 91%, yang berarti model berhasil menemukan 91% dari semua data kelas 1 yang sebenarnya. Sementara itu, algoritma Single Layer Perceptron memberikan akurasi sebesar 99%, yang menunjukkan bahwa model ini sangat baik dalam mengklasifikasikan data secara keseluruhan. Pada kelas 0 (Nondemented), algoritma Single Layer Perceptron memiliki presisi sebesar 94%, yang berarti 94% dari data yang diprediksi sebagai kelas 0 adalah benar-benar kelas 0. Recall pada kelas 0 adalah 73%, yang berarti model berhasil menemukan 73% dari semua data kelas 0 yang sebenarnya. Pada kelas 1 (Demented), algoritma Single Layer Perceptron memiliki presisi sebesar 97%, yang berarti 97% dari data yang diprediksi sebagai kelas 1 adalah benar-benar kelas 1. Recall pada kelas 1 adalah 100%, yang berarti model berhasil menemukan semua data kelas 1 yang sebenarnya. Berdasarkan nilai akurasi, presisi, dan recall yang lebih tinggi pada algoritma Single Layer Perceptron, dapat disimpulkan bahwa model ini memberikan hasil prediksi yang lebih baik dan lebih akurat dalam mengklasifikasikan dataset Alzheimer dibandingkan dengan algoritma K-Nearest Neighbor.

IV. KESIMPULAN

Berdasarkan hasil penelitian ini, diperoleh kesimpulan bahwa algoritma K-Nearest Neighbor (K-NN) memberikan prediksi terbaik dalam mendeteksi penyakit Alzheimer. Pada pengujian dengan variasi parameter K dari 1 sampai 9, hasil terbaik ditemukan pada K=5, yang menghasilkan nilai akurasi, presisi, dan recall yang sangat baik. Rentang nilai tersebut berkisar antara 91% sampai 100%. Hal ini menunjukkan bahwa mempertimbangkan 5 tetangga terdekat dalam proses klasifikasi memberikan hasil optimal dalam mengklasifikasikan pasien Alzheimer. Di sisi lain, algoritma Single Layer Perceptron (SLP) juga memberikan hasil yang baik dalam mendeteksi penyakit Alzheimer. Rentang nilai akurasi, presisi, dan recall pada SLP berkisar antara 97% sampai 100%. Performansi yang tinggi ini menunjukkan bahwa SLP mampu memberikan prediksi yang akurat dan tepat dalam mengklasifikasikan kasus-kasus penyakit Alzheimer pada dataset yang digunakan. Meskipun SLP menghasilkan performansi yang sedikit lebih tinggi dibandingkan dengan K-NN dalam penelitian ini, penting untuk mempertimbangkan konteks dan kebutuhan spesifik dalam memilih algoritma. Setiap algoritma memiliki kelebihan dan kelemahan masing-masing, serta dapat memberikan hasil yang optimal tergantung pada karakteristik dataset dan tujuan yang ingin dicapai. Dalam konteks deteksi dini penyakit Alzheimer, algoritma SLP dapat menjadi pilihan yang baik karena mampu memberikan akurasi tinggi dan prediksi yang tepat.

V. DAFTAR PUSTAKA

- Agung Riansa, D., Widodo, Prasetya Adhi, B., 2019. Pengenalan Tanda Tangan Menggunakan Algoritma Single Layer Perceptron. *PINTER J. Pendidik. Tek. Inform. dan Komput.* 3, 1–6. <https://doi.org/10.21009/pinter.3.1.1>
- Akbar, F., Rahmadden, 2022. *Jurnal Politeknik Caltex Riau* Komparasi Algoritma Machine Learning untuk Memprediksi Penyakit Alzheimer. *J. Komput. Terap.* 8, 236–245.
- Aulia, R., 2021. Dimensia Serang 55 Juta Penduduk, WHO: Usia 20 hingga 40 Tahun Bisa alami Penurunan Daya Ingat. URL <https://indobalnews.pikiran-rakyat.com/lifestyle/pr-882522175/dimensia-serang-55-juta-penduduk-who-usia-20-hingga-40-tahun-bisa-alami-penurunan-daya-ingat>
- Baharuddin, M.M., Azis, H., Hasanuddin, T., 2019. Analisis Performa Metode K-Nearest Neighbor Untuk Identifikasi Jenis Kaca. *Ilk. J. Ilm.* 11, 269–274. <https://doi.org/10.33096/ilkom.v11i3.489.269-274>
- Fansyuri, M., 2020. Analisa algoritma klasifikasi k-nearest neighbor dalam menentukan nilai akurasi terhadap kepuasan pelanggan (study kasus pt. Trigatra komunikatama). *Humanika J. Ilmu Sos. Pendidikan, dan Hum.* 3, 29–33.
- Febriana, F., Riva, L.S., Salomo, R., Piero, S., Ikramsyah, M.A., Santoni, M.M., 2021. Perbandingan Klasifikasi Naive-Bayes dan KNN untuk Mengidentifikasi Jenis Buah Apel dengan Ekstraksi Ciri LBP dan HSV. *Semin. Nas. Mhs. Ilmu Komput. dan Apl.* 191–201.
- Ihham, A., 2020. Hybrid Metode Bootstrap Dan Teknik Imputasi Pada Metode C4-5 Untuk Prediksi Penyakit Ginjal Kronis. *Statistika* 8, 43–51.
- Istighfarizky, F., Sanjaya ER, N.A., Widiartha, I.M., Astuti, L.G., Putra, I.G.N.A.C., Suhartana, I.K.G., 2022. Klasifikasi Jurnal menggunakan Metode KNN dengan Mengimplementasikan Perbandingan Seleksi Fitur. *JELIKU (Jurnal Elektron. Ilmu Komput. Udayana)* 11, 167. <https://doi.org/10.24843/jlk.2022.v11.i01.p18>
- Kurnia, F., Kom, S., Kurniawan, J., St, I.F., 2019. Klasifikasi Keluarga Miskin Menggunakan Metode K- Nearest Neighbor Berbasis Euclidean Distance 230–239.
- Mada Abdillah, T., 2017. Rancangan Bangun Sistem Pengklasifikasi Kecepatan Maksimum Kereta Api pada Jalur Klakah-Pasirian Menggunakan Metode Single Layer Perceptron. *Digit. Repos. Univ. Jember.*
- Muhammad Varriel Avenazh Nizar, Sirajuddin Hawari, Ahmad Nur Ihsan Purwanto, 2022. Membandingkan Metode Jaringan Syaraf Tiruan Backpropagation Dan Learning Vector Quantization Dengan Opencv Pada Pengenalan Wajah. *Jural Ris. Rumpun Ilmu Tek.* 1, 107–114.
- Najwa, M., Warsito, B., Ispriyanti, D., 2017. Pemodelan Jaringan Syaraf Tiruan Dengan Algoritma One Step Secant Backpropagation dalam Return Kurs Rupiah Terhadap Dolar Amerika Serikat. *J. Gaussian* 6, 61–70.
- Nasution, D.A., Khotimah, H.H., Chamidah, N., 2019. Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN. *Comput. Eng. Sci. Syst. J.* 4, 78. <https://doi.org/10.24114/cess.v4i1.11458>
- Pratama, Y., Roberto Tampubolon, A., Diantri Sianturi, L., Diana Manalu, R., Friez Pangaribuan, D., 2019. Implementation of Sentiment Analysis on Twitter Using Naïve Bayes Algorithm to Know the People Responses to Debate of DKI Jakarta Governor Election. *J. Phys. Conf. Ser.* 1175. <https://doi.org/10.1088/1742-6596/1175/1/012102>
- Rismala; Ali, I., Rizki Rinaldi, A., 2023. Penerapan Metode K-Nearest Neighbor untuk Prediksi 7, 585–590.
- Sa'dan, A., Haryanto, H., Astuti, S., Rahayu, Y., 2019. Agen Cerdas Berbasis Fuzzy Tsukamoto pada Sistem Prediksi Banjir. *Eksplora Inform.* 8, 104–111. <https://doi.org/10.30864/eksplora.v8i2.154>
- Safaat, M., Sahari, A., Lusiyanti, D., 2020. Implementasi Metode K-Nearest Neighbor Untuk Mengklasifikasi Jenis Penyakit Katarak. *J. Ilm. Mat. Dan Terap.* 17, 92–99. <https://doi.org/10.22487/2540766x.2020.v17.i1.15184>
- Sartika, D., Sensuse, D.I., 2017. Perbandingan Algoritma Klasifikasi Naive Bayes, Nearest Neighbour, dan Decision Tree pada Studi Kasus Pengambilan Keputusan Pemilihan Pola Pakaian. *J. Tek. Inform. Dan Sist. Inf.* 1, 151–161.
- Wildah, S.K., Agustiani, S., S, M.R.R., Gata, W., Nawawi, H.M., 2020. Deteksi Penyakit Alzheimer Menggunakan Algoritma Naïve Bayes Dan Correlation Based Feature Selection. *J. Inform.* 7, 166–173. <https://doi.org/10.31294/ji.v7i2.8226>
- Yuli Mardi, 2019. Data Mining: Klasifikasi Menggunakan Algoritma C4 . 5 Data mining merupakan bagian dari tahapan proses Knowledge Discovery in Database (KDD) . *Jurnal Edik Informatika. J. Edik Inform.* 2.

