



IMPLEMENTASI ALGORITMA K-NEAREST NEIGHBOR (K-NN) DAN SINGLE LAYER PERCEPTRON (SLP) DALAM PREDIKSI PENYAKIT SIROSIS BILIARI PRIMER

Annisa Nurba Iffah'da ¹⁾, Anita Desiani ²⁾

¹ Program Studi Matematika, Universitas Sriwijaya

² Program Studi Matematika, Universitas Sriwijaya

email: ¹ 08011282025039@student.unsri.ac.id, ² anita_desiani@unsri.ac.id

ARTICLE INFO

Article History:

Received : 25 May 2022

Accepted : 20 June 2022

Published : 30 June 2022

Keywords:

K-Nearest Neighbor

PBC

Percentage Split

Primary Biliary Cirrhosis

Single Layer Perceptron

IEEE style in citing this article:

A. N. Iffah'da and A. Desiani, "Implementasi Algoritma K-Nearest Neighbor (K-NN) dan Single Layer Perceptron (SLP) Dalam Prediksi Penyakit Sirosis Biliari Primer", *Jurnal ilmiah.informatika*, vol. 7, no. 1, pp. 65-74, Jun. 2022.

ABSTRACT

Primary biliary cirrhosis is a chronic cholestatic liver disease that can lead to liver failure. The majority of individuals who suffer from this disease are women. Primary biliary cirrhosis is recorded as contributing to mortality worldwide with a percentage of 0.6% to 2.0%. However, so far, randomized trials have shown that some immunosuppressant or immunosuppressive drugs do not play a major role in patients with primary biliary cirrhosis. Therefore, early detection is important to start treatment and planning for appropriate medical needs. The results of the processing accuracy with the K-NN algorithm of 76.2% and the SLP algorithm of 63% using the Percentage Split method show that the K-NN algorithm is better for early detection of primary biliary cirrhosis. The K-Nearest Neighbor algorithm is able to perform early detection of primary biliary cirrhosis with a precision of 77% and recall of 75% with the hope that the percentage of mortality worldwide can decrease. However, the K-NN algorithm is not superior in retrieving information in patients with primary biliary cirrhosis. On the other hand, the SLP algorithm is superior in retrieving information in patients with primary biliary cirrhosis with a recall value of 65%.

Corresponding Author:

Anita Desiani

Universitas Sriwijaya

© 2022 Jurnal Ilmiah Informatika (Scientific Informatics Journal) with CC BY NC licence

1. PENDAHULUAN

Sirosis Biliar Primer atau *Primary Biliary Cirrhosis* (PBC) merupakan diagnosa penyakit autoimun hati dan penyakit hati kolestatis kronis yang mengganggu metabolisme empedu (asam) yang ditandai dengan terdeteksinya *Anti Mitochondrial Antibody* (AMA) dalam serum, terdapat antinuklir antibodi, serta granulomatosa progresif yang menyebabkan sirosis dan pada akhirnya terjadi transplantasi hati [1]. Sirosis hati ditimbulkan melalui peradangan portal yang perlahan-lahan berkembang menjadi fibrosis obliteratif [2]. Pasien dengan gejala PBC umumnya mengalami kelelahan, hipertensi portal, osteoporosis, defisiensi vitamin larut lemak, dan/atau infeksi saluran kemih asimtomatik berulang [3]. PBC rentan menyerang pada wanita usia 50 tahun ke atas, tetapi spektrum penyakitnya diakui secara global pada pasien dewasa [4]. Pengidap penyakit ini didominasi oleh perempuan dengan rasio antara perempuan dan laki-laki yakni 8:1 [5].

Studi mengenai kualitas hidup pada pasien PBC telah dilakukan secara konvensional menggunakan kualitas hidup terkait kesehatan yang ada (*Health Related Quality of Life*), tetapi penilaian HRQOL sangat dipertanyakan karena ekstrapolasi penggunaannya secara klinis yang terbatas [6]. Sehingga, pada penelitian ini akan dilakukan deteksi dini dengan menggunakan metode penyelesaian matematika, salah satunya adalah penggunaan pendekatan data mining.

Data mining merupakan salah satu bidang keilmuan yang mengkombinasikan teknik dari *machine learning*, pengenalan pola, statistik, *database*, dan visualisasi [7]. Deteksi dini akan dilakukan dengan dua algoritma, yaitu algoritma K-Nearest

Neighbor (K-NN) dan algoritma *Single Layer Perceptron* (SLP). K-*Nearest Neighbor* (K-NN) adalah algoritma yang mengklasifikasikan objek berdasarkan data training terdekat di ruang fitur [8]. Beberapa kelebihan yang dimiliki oleh algoritma K-NN antara lain adalah melakukan training dengan cepat, sederhana dan mudah dipelajari, dan efektif jika data training besar. Sedangkan beberapa kekurangan K-NN antara lain adalah nilai k bias, komputasi kompleks, dan mudah tertipu dengan atribut yang tidak relevan [9]. Salah satu algoritma yang dapat mengatasi mudahnya tertipu dengan atribut yang tidak relevan adalah algoritma *Single Layer Perceptron* (SLP). *Single Layer Perceptron* merupakan jaringan satu lapisan dengan pembobotan yang terhubung [10]. Beberapa kelebihan SLP antara lain adalah mampu memperoleh pengetahuan meski tidak ada kepastian pada data yang digunakan, data yang berpola tertentu dapat digeneralisasi dan diekstraksi, dan pola pengetahuan dapat dibuat melalui penyesuaian diri atau kemampuan belajar [11]. Sedangkan beberapa kekurangan yang dimiliki algoritma SLP antara lain adalah tidak mampu menyelesaikan lebih dari dua kelas [12].

Berdasarkan kelebihan dan kekurangan yang dimiliki masing-masing kedua algoritma tersebut, akan dibandingkan hasil diagnosa antara algoritma K-NN dan algoritma SLP pada penyakit sirosis biliar primer. Perbandingan ini digunakan untuk memperoleh algoritma terbaik yang dapat digunakan untuk deteksi dini penyakit sirosis biliar primer. Pada kedua algoritma yang digunakan, akan dilakukan perbandingan masing-masing kinerja algoritma dengan nilai akurasi, presisi, dan *recall*.

2. METODE PENELITIAN

2.1 Deskripsi Data

Data yang digunakan dalam penelitian ini yaitu dataset yang diperoleh dari situs Kaggle dengan judul "Mayo Clinic Primary Biliary Cirrhosis Data" dengan format data yaitu csv (<https://www.kaggle.com/datasets/jixing475/mayo-clinic-primary-biliary-cirrhosis-data>). Terdapat 418 data yang terdiri dari 18 atribut dengan 17 di antaranya yaitu *trt*, *age*, *sex*, *scites*, *hepato*, *spiders*, *edema*, *bili*, *chol*, *albumin*, *copper*, *alk.phos*, *ast*,

trig, *platelet*, *protimes*, dan *stage*. Sedangkan atribut kelas yaitu status yang terdiri dari PBC, nonPBC, dan Converted. Pada kelas Converted akan digabungkan dengan kelas PBC. Sehingga, pada atribut status, terdapat dua kelas yang terdiri dari PBC dan nonPBC. Terdapat beberapa atribut yang memiliki data kosong. Untuk melihat informasi atribut secara lengkap yang terdapat pada dataset penyakit Sirosis Bilier Primer dapat dilihat pada Tabel 1.

Tabel 1. Atribut dan Informasi Data

Atribut	Keterangan Atribut	Data Kosong
<i>status</i>	Kelas nonPBC (0), PBC (1), Converted (2)	<i>Null</i>
<i>trt</i>	Prosedur yang disarankan untuk dijalani pengidap tinnitus. (1 : Tidak, 2 : Ya)	106
<i>age</i>	Usia pasien. (26 tahun – 78 tahun)	<i>Null</i>
<i>sex</i>	Jenis kelamin <i>Male</i> (Laki-Laki) dan <i>Female</i> (Perempuan)	<i>Null</i>
<i>ascites</i>	Pembengkakan pada perut yang disebabkan karena akumulasi cairan, sering kali berhubungan dengan penyakit hati. (1 : Ya, 0 : Tidak)	106
<i>hepato</i>	Pembengkakan hati (1 : Ya, 0 : Tidak)	106
<i>spiders</i>	Suatu kondisi yang menyebabkan kumpulan pembuluh darah kecil yang menyerupai sarang laba-laba terlihat pada permukaan kulit. (1 : Ya, 0 : Tidak)	106
<i>edema</i>	Faktor Skala Atlas; faktor penskalaan volume untuk ukuran otak. (1 : Besar, 0.5 : Sedang, 0 : Kecil)	<i>Null</i>
<i>bili</i>	Penumpukan cairan dalam jaringan tubuh. (0,3-28 miligram per desiliter)	<i>Null</i>
<i>chol</i>	Kadar kolesterol. (120-1775 miligram per desiliter)	134
<i>albumin</i>	Protein pada darah yang membentuk sebagian besar plasma darah. (1.96-4.64 gram per desiliter)	<i>Null</i>
<i>copper</i>	Mineral mikro yang cukup penting bagi tubuh selain zat besi dan zinc. (4-588 mikrogram per desiliter)	108
<i>alk.phos</i>	Alkaline phosphatase atau tes ALP adalah tes yang mengukur jumlah enzim alkaline fosfatase dalam aliran darah seseorang. (289-13862.4 iu per liter)	106
<i>ast</i>	Protein yang dihasilkan oleh sel-sel hati. (26.35-457.25 u per liter)	106
<i>trig</i>	Kondisi di mana kandungan trigliserida dalam darah di atas batas wajar. (33-598 miligram per desiliter)	136
<i>platelet</i>	Jumlah trombosit per mikroliter. (62-721 trombosit per microliter)	11

protime	Pemeriksaan untuk mengetahui proses pembekuan darah, yang diukur dalam satuan detik. (9-18 detik)	2
stage	Tingkat PBC. 1(terendah)-4 (tertinggi)	6

2.2 Praproses

2.2.1 Penanganan Data Hilang

Berdasarkan informasi pada Tabel 1, terdapat 12 dari 18 atribut yang memiliki data kosong. Pada atribut yang bertipe data numerik akan dilakukan pengisian data dengan menggunakan nilai modus. Sedangkan untuk atribut yang bertipe data kategori akan dilakukan pengisian data dengan menggunakan nilai rata-rata.

2.2.2 Standarisasi Data

Tahap selanjutnya adalah standarisasi

data dikarenakan terdapat beberapa atribut yang memiliki *range* data yang cukup jauh. Standarisasi data akan dilakukan menggunakan *Min-Max Normalization* pada persamaan (1). Hal ini bertujuan untuk menghindari adanya salah satu atribut yang mendominasi. Informasi atribut yang memiliki *range* data yang cukup jauh dapat dilihat pada Tabel 1. Adapun atribut yang dimaksud adalah chol, copper, alk.phos, ast, trig, dan platelet.

$$\text{normalized}(x) = \frac{\minRange + (x \text{ minValue})(\maxRange - \minRange)}{\maxValue - \minValue} \quad (1)$$

2.3 Percentage Split

Pada penelitian ini data akan dibagi menjadi dua bagian, yaitu data testing dan data training. Untuk menentukan data testing dan data training digunakan split data. Presentase yang digunakan adalah 20%. Artinya, 20% datanya menjadi data testing dan sisanya yaitu 80% menjadi data training secara acak.

2.4 K-Nearest Neighbor (KNN)

K-Nearest Neighbor (KNN) merupakan algoritma untuk melakukan klasifikasi tehadap objek baru berdasarkan nilai (K) tetangga terdekatnya [13]. Langkah-langkah untuk menghitung algoritma K-NN adalah sebagai berikut:

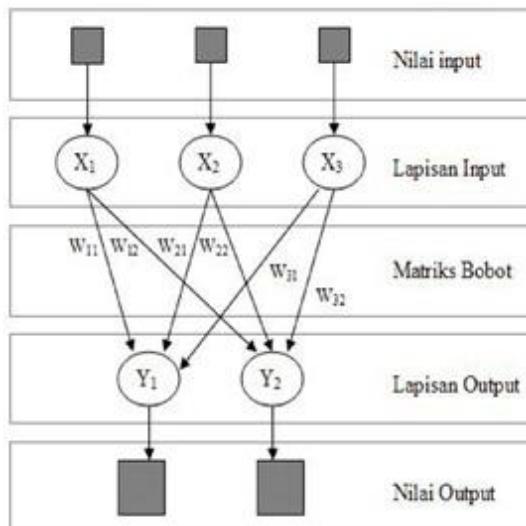
1. Menentukan nilai k, yaitu jumlah tetangga yang memiliki kemiripan dengan data yang akan dicek pelabelannya.
2. Menghitung kuadrat jarak *Euclid* masing-masing objek terhadap *training* data yang diberikan dengan menggunakan persamaan (2).

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

3. Kemudian mengurutkan objek-objek tersebut ke dalam kelompok yang mempunyai jarak *Euclid* terkecil.
4. Mengumpulkan label kelas Y (Klasifikasi K-Nearest Neighbor).
5. Dengan menggunakan kategori K-Nearest Neighbor yang paling mayoritas maka dapat diprediksi nilai *query instance* yang telah dihitung.

2.5 Single Layer Perceptron (SLP)

Single Layer Perceptron (SLP) atau juga disebut sebagai *perceptron* merupakan salah satu arsitektur dari Jaringan Syaraf Tiruan (JST) yang memiliki satu lapisan dengan bobot terhubung yang nantinya akan menerima masukan lalu akan diolah secara langsung untuk memperoleh keluaran tanpa harus melalui lapisan tersembunyi [14]. Single Layer Perceptron terdiri dari nilai *input*, lapisan *input*, matriks bobot, lapisan *output*, dan nilai *output*. Untuk penggambaran yang lebih jelas, dapat dilihat pada Gambar 1.



Gambar 1. Arsitektur Single Layer Perceptron

Langkah-langkah untuk menghitung algoritma *Single Layer Perceptron* adalah sebagai berikut [11]:

1. Mengatur nilai *learning rate* lebih dari 0 dan *threshold* sama dengan 0. Inisialisasi nilai bobot dan bias sama dengan 0 atau beberapa nilai secara acak.
2. Mengatur aktivitasi untuk vektor masukan dengan persamaan (3).

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

3. Menghitung nilai keluaran dan nilai *error* dengan persamaan (5) dan (6).

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

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

4. Jika klasifikasi sesuai atau \$y \neq t\$ atau nilai \$t = \theta\$, maka kondisi berhenti akan bernilai "benar". Jika yang terjadi sebaliknya, kondisi bernilai "salah", maka akan dilakukan perbaikan bobot dan bias pola menggunakan persamaan (7) dan (8).

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

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

5. Ulangi langkah-langkah 2 sampai 6 dengan batasan nilai *epoch* \$k\$ untuk memproses data *training* dengan mengatur dataset yang mempunyai nilai unit masukan \$q = 1, 2, 3, \dots, Q\$ sampai proses menghasilkan nilai kelas yang tepat.

2.6 Analisis Hasil

Untuk mengevaluasi keakuratan algoritma K-Nearest Neighbor dan *Single Layer Perceptron*, pada penelitian ini akan digunakan *Confusion Matrix*. *Confusion Matrix* merupakan salah satu metode yang digunakan untuk mengukur kinerja suatu klasifikasi [15]. *Confusion Matrix* akan menampilkan visualisasi kinerja dari algoritma klasifikasi menggunakan data dalam matriks yang membandingkan klasifikasi yang dilakukan oleh sistem dengan hasil klasifikasi yang seharusnya. Hasil yang diperoleh direpresentasikan dalam empat istilah, yaitu *True Positif* (TP), *False Positif* (FP), *True Negatif* (TN), dan *False Negatif* (FN).

Tabel 2. *Confusion Matrix*

<i>Actual</i>	<i>Prediction</i>	
	<i>Negative</i>	<i>Positive</i>
<i>Negative</i>	<i>True Negative</i> (TN)	<i>False Positive</i> (FP)
<i>Positive</i>	<i>False Negative</i> (FN)	<i>True Positive</i> (TP)

Ketepatan klasifikasi dapat dilihat dari akurasi klasifikasi. Akurasi klasifikasi menunjukkan performansi model klasifikasi secara keseluruhan, dimana semakin tinggi akurasi klasifikasi, maka semakin baik performansi model klasifikasi, atau sebaliknya.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (9)$$

Presisi merupakan tingkat ketepatan antara informasi yang diminta oleh

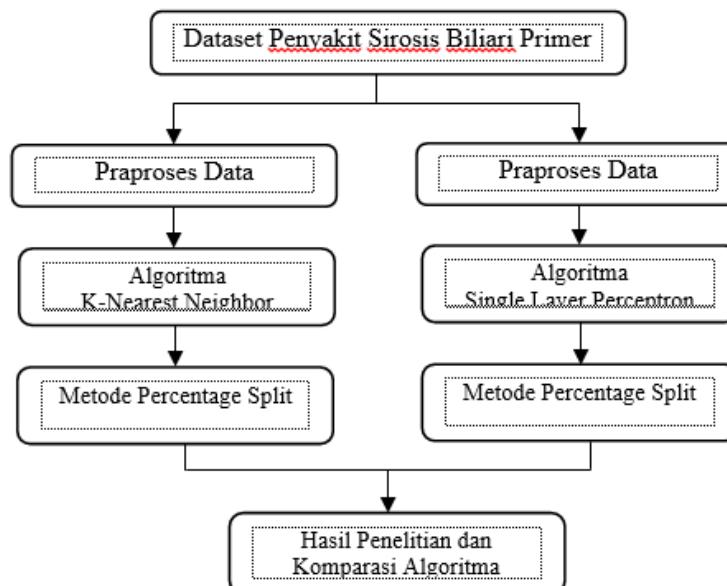
pengguna dengan jawaban yang diberikan oleh sistem.

$$\text{Presisi} = \frac{TP}{TP+FP} \quad (10)$$

Recall merupakan tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi.

$$\text{Recall} = \frac{TP}{TP+FN} \quad (11)$$

Secara umum, tahapan yang digunakan pada penelitian ini dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur *Single Layer Perceptron*

3. HASIL DAN PEMBAHASAN

3.1 *K-Nearest Neighbor (K-NN)*

Untuk menentukan nilai *k* terbaik pada algoritma K-NN digunakan percobaan beberapa nilai *k*. Pada

penelitian ini, data akan dilakukan percobaan terhadap nilai *k* sebanyak 9 nilai, yaitu 1, 2, 3, 4, 5, 6, 7, 8 dan 9. Adapun hasil dari setiap pengimplementasian nilai *k* dapat dilihat pada Tabel 3.

Tabel 3. Hasil Pemodelan Algoritma *K-Nearest Neighbor*

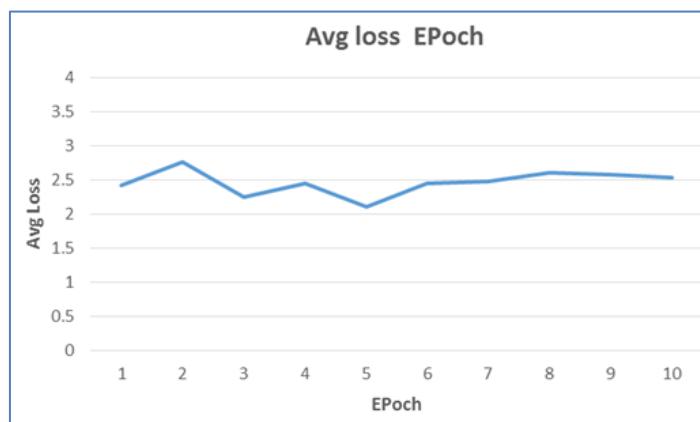
K	Target Kelas	Percentage Split			Akurasi
		Presisi	Recall	Akurasi	
1	0	68%	64%	60.7%	
	1	51%	56%		
2	0	69%	90%	69%	
	1	71%	36%		
3	0	72%	82%	70.2%	
	1	67%	53%		
4	0	63%	84%	66.6%	
	1	74%	49%		

	0	80%	81%	
5	1	66%	63%	75%
	0	58%	93%	
6	1	83%	35%	63%
	0	74%	87%	
7	1	80%	63%	76.2%
	0	67%	85%	
8	1	81%	60%	72.6%
	0	69%	78%	
9	1	62%	51%	66.6%

Dapat dilihat pada Tabel 3 bahwa nilai akurasi, presisi, dan *recall* yang telah diperoleh, nilai terbaik berdasarkan percobaan sebanyak 9 nilai k terdapat pada $k = 7$ dengan nilai akurasi sebesar 76.2%. Nilai presisi dan *recall* pada kelas 0 (PBC) berturut-turut, yaitu 74% dan 87%. Sedangkan nilai presisi dan *recall* pada kelas 1 (nonPBC) berturut-turut, yaitu 80% dan 63%.

3.2 K-Nearest Neighbor (K-NN)

Pada penelitian ini, algoritma *Single Layer Perceptron* pada data training menggunakan 10 epoch (proses algoritma *perceptron* yang terjadi dalam pencarian). Dengan kata lain, data akan di-training sebanyak 10 kali. Nilai *learning rate* yang digunakan pada penelitian ini adalah 0.3. Hasil yang diperoleh dapat dilihat pada Gambar 3.



Gambar 3. Hasil Training Algoritma Single Layer Perceptron

Seperti yang dapat dilihat pada Gambar 3 bahwa epoch ke-9 dan ke-10 menghasilkan nilai *Avg Loss* yang nyaris stabil. Ini menandakan bahwa training yang telah dilakukan memberikan hasil yang terbaik. Jika telah memperoleh hasil yang terbaik, maka iterasi berhenti.

Sehingga, akan dilanjutkan pada data testing.

Pemodelan dataset penyakit sirosis biliar primer atau PBC pada data testing menghasilkan nilai akurasi, presisi, dan *recall* yang dapat dilihat pada Tabel 4.

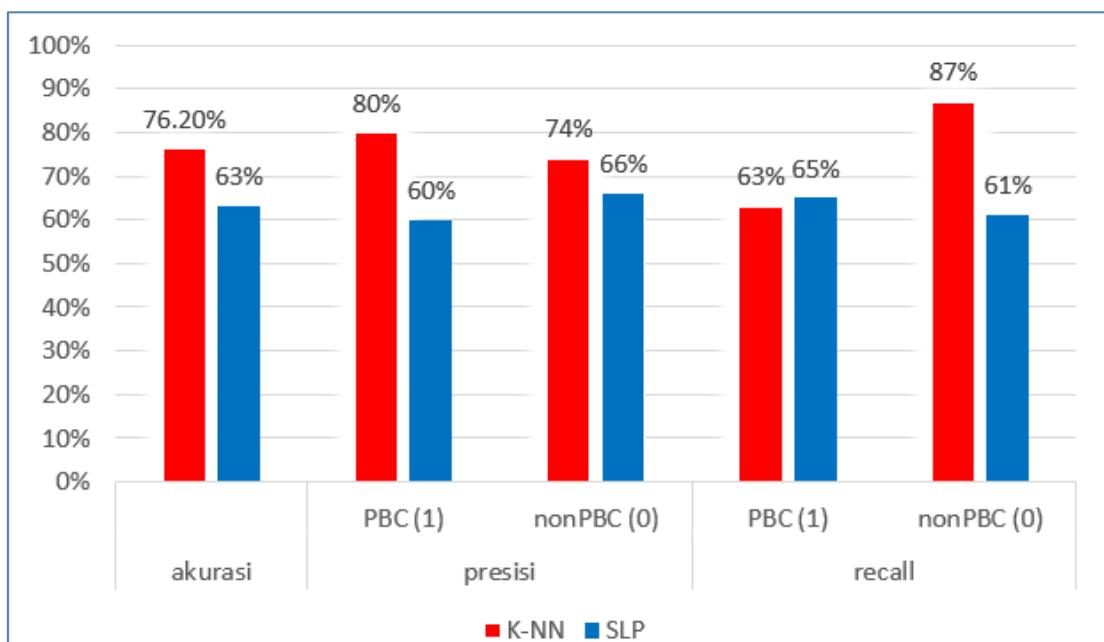
Tabel 4. Hasil Pemodelan Algoritma Single Layer Perceptron

Kelas	Presisi	Recall	Akurasi
nonPBC (0)	66%	61%	
PBC (1)	60%	65%	63%

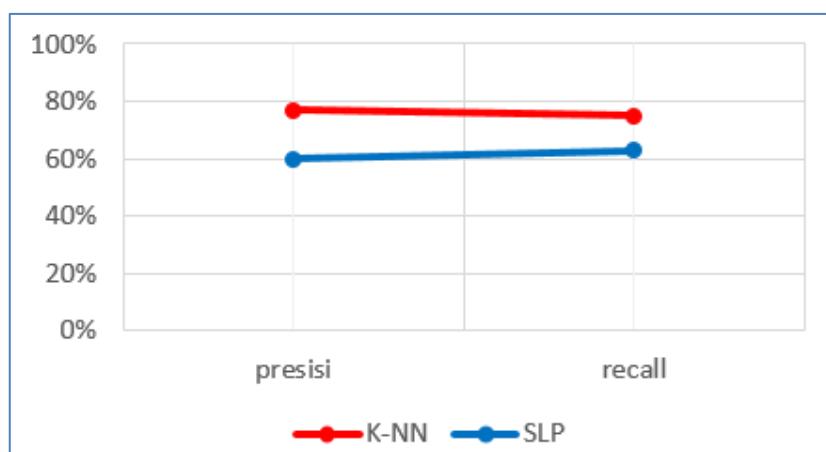
3.3 Perbandingan Kedua Algoritma

Berdasarkan nilai akurasi, presisi, dan recall yang telah diperoleh dari masing-masing algoritma, yaitu algoritma K-Nearest Neighbor dan Single Layer Perceptron, dapat dibandingkan dari parameter tersebut menunjukkan bahwa algoritma K-Nearest Neighbor (K-NN) menghasilkan nilai akurasi, presisi, dan recall yang lebih tinggi dibandingkan dengan nilai akurasi, presisi, dan recall yang diperoleh menggunakan algoritma Single Layer Perceptron (SLP). Untuk nilai akurasi diperoleh sebesar 76.20% pada algoritma K-NN dan 63% pada algoritma

SLP. Untuk nilai presisi diperoleh sebesar 77% pada algoritma K-NN dan 60% pada algoritma SLP. Untuk nilai recall diperoleh sebesar 75% pada algoritma K-NN dan 63% pada algoritma SLP. Perbandingan nilai akurasi, presisi, dan recall dapat dilihat secara ringkas pada Gambar 4. Hasil nilai presisi dan nilai recall yang memiliki nilai di setiap kelasnya, yaitu kelas PBC (1) dan nonPBC (0), akan dihitung rata-ratanya dari dua kelas tersebut. Nilai rata-rata presisi dan recall yang dibandingkan dari seluruh label dapat dilihat pada Gambar 5.



Gambar 4. Perbandingan Nilai Akurasi, Presisi, dan Recall



Gambar 5. Rata-rata Keseluruhan Nilai Presisi dan Recall dengan Metode Percentage Split

Dari gambar 5 dapat dilihat nilai presisi dan *recall* yang dihasilkan oleh algoritma K-NN ataupun algoritma SLP menunjukkan bahwa algoritma K-NN lebih baik digunakan untuk pendekripsi dini penyakit sirosis biliar primer dibandingkan dengan algoritma SLP.

4. KESIMPULAN

Hasil akurasi dari kedua algoritma *K-Nearest Neighbor* (K-NN) sebesar 76.2% dan *Single Layer Perceptron* (SLP) sebesar 62%, menjelaskan bahwa kedua algoritma tersebut baik dalam melakukan deteksi dini pada penyakit sirosis biliar primer dalam penelitian ini. Akan tetapi, berdasarkan hasil percobaan yang diperoleh menunjukkan bahwa algoritma K-NN merupakan algoritma terbaik untuk mendekripsi dini penyakit sirosis biliar primer dibandingkan dengan algoritma SLP. Hal ini mengacu pada nilai akurasi, presisi, dan *recall* pada algoritma K-NN yang lebih tinggi dibandingkan dengan nilai akurasi, presisi, dan *recall* pada algoritma SLP. Algoritma K-NN mampu melakukan pendekripsi dini penyakit sirosis biliar primer dengan presisi sebesar 77% dan *recall* sebesar 75% dengan harapan bahwa persentase angka kematian di seluruh dunia dapat menurun. Namun, algoritma K-NN tidak lebih unggul dalam menemukan kembali informasi pada pasien yang mengidap penyakit sirosis biliar primer. Sebaliknya algoritma SLP lebih unggul dalam menemukan kembali informasi pada pasien yang mengidap penyakit sirosis biliar primer dengan nilai *recall* sebesar 65%.

5. REFERENSI

- [1] V. I. Reshetnyak, "Primary biliary cirrhosis: Clinical and laboratory criteria for its diagnosis," *World J. Gastroenterol.*, vol. 21, no. 25, pp. 7683–7708, 2015, doi: 10.3748/wjg.v21.i25.7683.
- [2] J. Mattner, "Impact of microbes on the pathogenesis of primary biliary cirrhosis (PBC) and primary sclerosing cholangitis (PSC)," *Int. J. Mol. Sci.*, vol. 17, no. 11, 2016, doi: 10.3390/ijms17111864.
- [3] E. Jenny Heathcote, "Management of primary biliary cirrhosis," *Hepatology*, vol. 31, no. 4, pp. 1005–1013, 2000, doi: 10.1053/he.2000.5984.
- [4] G. M. Hirschfield *et al.*, "The British Society of Gastroenterology/UK-PBC primary biliary cholangitis treatment and management guidelines," *Gut*, vol. 67, no. 9, pp. 1568–1594, 2018, doi: 10.1136/gutjnl-2017-315259.
- [5] T. Kumagi and E. J. Heathcote, "Primary biliary cirrhosis," *Orphanet J. Rare Dis.*, vol. 3, no. 1, pp. 1–17, 2008, doi: 10.1186/1750-1172-3-1.
- [6] A. Jacoby *et al.*, "Development, validation, and evaluation of the PBC-40, a disease specific health related quality of life measure for primary biliary cirrhosis," *Gut*, vol. 54, no. 11, pp. 1622–1629, 2005, doi: 10.1136/gut.2005.065862.
- [7] D. R. W. Z. M. Jollyta, *Konsep Data Mining dan Penerapan*. Yogyakarta: Deepublish, 2020.
- [8] S. B. Imandoust and M. Bolandraftar, "Application of K-Nearest Neighbor (KNN) Approach for Predicting Economic Events: Theoretical Background," *Int. J. Eng. Res. Appl.*, vol. 3, no. 5, pp. 605–610, 2013.
- [9] G. A. Rosso, "Milton," *William Blake Context*, no. September, pp. 184–191, 2019, doi: 10.1017/9781316534946.021.
- [10] M. Yanto, "Penerapan Jaringan Syaraf Tiruan Dengan Algoritma Perceptron Pada Pola Penentuan Nilai Status Kelulusan Sidang Skripsi," *J. Teknoif*, vol. 5, no. 2, pp.

- 79–87, 2017, doi: 10.21063/jtif.2017.v5.2.79-87.
- [11] T. Mada Abdillah, "Rancangan Bangun Sistem Pengklasifikasi Kecepatan Maksimum Kereta Api pada Jalur Klakah-Pasirian Menggunakan Metode Single Layer Perceptron," *Digit. Repos. Univ. Jember*, 2017.
- [12] M. Najwa, B. Warsito, and D. Ispriyanti, "Pemodelan Jaringan Syaraf Tiruan Dengan Algoritma One Step Secant Backpropagation dalam Return Kurs Rupiah Terhadap Dolar Amerika Serikat," *J. Gaussian*, vol. 6, no. 1, pp. 61–70, 2017.
- [13] A. J. T, D. Yanosma, and K. Anggriani, "Implementasi Metode K-Nearest Neighbor (KNN) dan Simple Additive Weighting (SAW) Dalam Pengambilan Keputusan Seleksi Penerimaan Anggota Paskibraka," vol. III, no. 0065, pp. 98–112, 2016.
- [14] M. D. Wuryandari and I. Afrianto, "Perbandingan Metode Jaringan Syaraf Tiruan Backpropagation Dan Learning Vector Quantization Pada Pengenalan Wajah," *Komputa*, vol. 1, no. 1, pp. 45–51, 2012.
- [15] Karsito and S. Susanti, "Klasifikasi Kelayakan Peserta Pengajuan Kredit Rumah Dengan Algoritma Naïve Bayes Di Perumahan Azzura Residencia," *J. Teknol. Pelita Bangsa*, vol. 9, pp. 43–48, 2019.