

OPTIMASI ALGORITMA K-NEAREST NEIGHBOR (KNN) DENGAN NORMALISASI DAN SELEKSI FITUR UNTUK KLASIFIKASI PENYAKIT LIVER

Siti Zulaikhah HR, Abdul Aziz, Wahyudi Harianto

Program Studi Teknik Informatika S1, Fakultas Sains dan Teknologi
Universitas PGRI Kanjuruhan Malang, Jalan S.Supriadi No.48 Malang, Indonesia
yanti.rukkmana@gmail.com

ABSTRAK

Sulitnya mengenali penyakit *liver* sejak dini menjadi permasalahan yang sering terjadi. Dengan berkembangnya teknologi, saat ini diagnosis penyakit *liver* dapat menggunakan metode *data mining*. Penelitian ini bertujuan untuk mengetahui penerapan seleksi fitur dan normalisasi data untuk mencari model optimasi untuk klasifikasi penyakit *liver* dengan algoritma *K-Nearest Neighbor*. Metode *K-Nearest Neighbor* dipilih karena memiliki prinsip sederhana dan mudah digunakan, tetapi pada beberapa penelitiannya memiliki akurasi relatif rendah. Proses klasifikasi pada penelitian ini dilakukan dengan melakukan pengisian data yang kosong setelah itu dilakukan pembobotan atribut dan normalisasi pada data yang terpilih. Pada penelitian ini nilai akurasi yang paling optimal didapat ketika menggunakan normalisasi *min-max*, dengan seleksi fitur *Information Gain* dan *Gain Ratio* digunakan nilai rata-rata untuk mengisi kekosongan data dengan menggunakan nilai $k = 10$. Sedangkan pada seleksi fitur *Symmetrical Uncertainty* dapat menggunakan nilai 0 untuk kekosongan data dan nilai $k = 5$.

Kata kunci: *K-Nearest Neighbor (KNN), Optimasi, Normalisasi, Seleksi Fitur*

1. PENDAHULUAN

Masalah yang ditimbulkan oleh penyakit *liver* adalah susah mengenali penyakit *liver* sejak dini, bahkan ketika penyakit tersebut sudah menyebar. Diagnosa penyakit *liver* yang lebih awal dapat meningkatkan tindak kelangsungan hidup pasien. Dengan perkembangan teknologi saat ini diagnosa penyakit dapat menggunakan metode *data mining*. Salah satu pengembangan dari *data mining* adalah klasifikasi. Metode klasifikasi banyak digunakan untuk menentukan keputusan sesuai pengetahuan baru yang didapat dari pengolahan data lampau menggunakan perhitungan suatu algoritma [1].

Metode yang digunakan untuk membangun model klasifikasi dalam penyakit *liver* yaitu *K-Nearest Neighbor (KNN)*. Karena pada penelitian ini sebelumnya yang dilakukan oleh [2] yang membandingkan kinerja algoritma *Naïve Bayes*, *Decision Tree* dan *K-Nearest Neighbor (KNN)* menunjukkan bahwa kinerja KNN memiliki nilai akurasi terendah dengan rata-rata 56,7%. Pada penelitian [3] mengusulkan untuk melakukan seleksi fitur dengan cara membuang atribut yang kurang berpengaruh terhadap data yang diujikan sebelum dilakukan klasifikasi dengan metode KNN.

Sedangkan dalam penelitian [4] menggunakan *gain ratio* sebagai dasar dalam pembobotan setiap atribut pada algoritma KNN. Dari penelitian tersebut, algoritma KNN dengan menggunakan seleksi fitur *gain ratio* dinilai lebih intuitif dan mudah dipahami. Hasil yang diperoleh dari penelitian tersebut mendapatkan peningkatan akurasi sebesar 5%.

Penelitian lain juga dilakukan dengan melakukan proses *preprocessing* dengan normalisasi dan mengisi *missing value*. Normalisasi dilakukan pada data yang telah dipilih atributnya berdasarkan proses seleksi fitur dan *missing value* dilakukan

dilakukan karena adanya data yang kosong atau tidak memiliki nilai atau informasi pada beberapa atributnya. Oleh karena itu pada penelitian ini berfokus pada peningkatan akurasi pada klasifikasi penyakit *liver* dengan menggunakan algoritma *K-Nearest Neighbor (KNN)* dengan menggunakan normalisasi pada data yang telah dilakukan seleksi fitur.

2. TINJAUAN PUSTAKA

2.1. Klasifikasi

Menurut [5] klasifikasi data mining merupakan penempatan suatu objek ke salah satu dari beberapa kategori yang telah ditetapkan sebelumnya. Klasifikasi merupakan suatu tipe data yang dianalisis dan dapat membantu untuk menentukan kelas dari sampel data yang ingin diklasifikasikan dan menemukan hubungan antar atribut.

2.2. K-Nearest Neighbor (KNN)

Perhitungan algoritma KNN menggunakan jarak antara seluruh seluruh data *training* dan data *testing*, dan kemudian data terdekat atau data yang paling banyak memiliki kemiripan akan diambil untuk klasifikasi [6]. Perhitungan algoritma KNN menggunakan jarak antara seluruh data *training* dan data *testing*, dan kemudian data terdekat atau data yang paling banyak memiliki kemiripan akan diambil untuk klasifikasi.

2.3. Seleksi Fitur

Seleksi fitur merupakan proses pemilihan atribut yang sesuai dari sekumpulan atribut yang banyak, Algoritma memroses data lebih cepat dengan mengurangi atribut atau fitur yang tidak relevan. Oleh karena itu, pemilihan seleksi fitur yang tepat akan menghasilkan hasil klasifikasi yang lebih cepat [7].

2.4. Information Gain

Information gain merupakan salah satu algoritma dalam machine learning yang populer dan memiliki keunggulan dalam membatasi pentingnya suatu atribut, karena tidak semua atribut dapat digunakan dalam proses klasifikasi sehingga akan membuat kinerja algoritma menjadi tidak efisien.

2.5. Gain Ratio

Peningkatan dari information gain dalam mengoptimalkan nilai yang normalisasi untuk fitur didalam klasifikasi, pada gain ratio memerlukan hasil perhitungan information gain. Sehingga gain ratio memerlukan hasil modifikasi dari perhitungan yang sama seperti information gain.

2.6. Symmetrical Uncertainty

Symmetrical Uncertainty merupakan suatu pendekatan untuk mengukur nilai suatu fitur dengan mengukur ketidakpastian simetris yang terkait dengan kelas dan mengkompensasi penyimpangan dalam metode seleksi fitur information gain [8].

2.7. Normalisasi

Proses normalisasi data dilakukan untuk menyamakan nilai data apabila terdapat perbedaan yang signifikan pada range nilai, sehingga memudahkan dalam penerapannya [9].

2.8. Missing Value

Missing value dapat terjadi karena informasi tentang objek sulit dicari, tidak diberikan atau informasi tersebut memang tidak ada. Missing value adalah masalah yang terjadi dalam penelitian. Adanya missing pada data yang dianalisis dapat menurunkan keakuratan dan kualitas data pada saat diolah [10].

2.9. Confusion Matrix

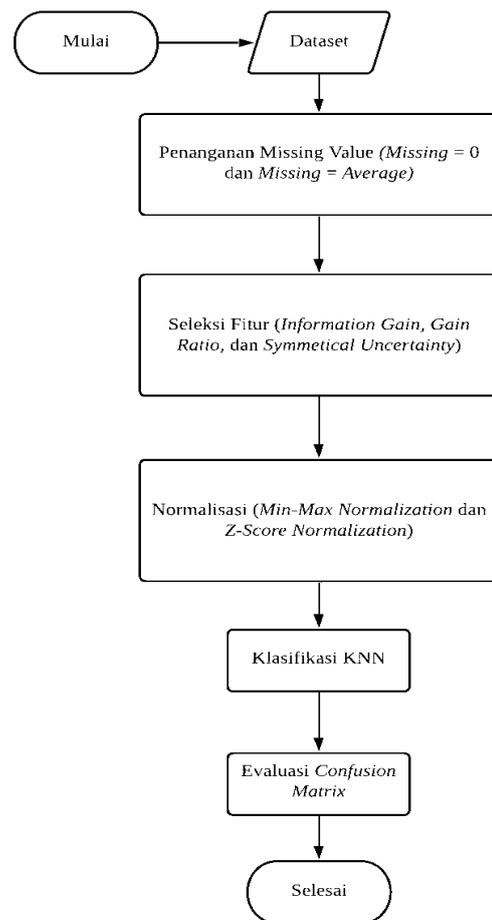
Confusion matrix merupakan alat untuk mengevaluasi model klasifikasi untuk memperkirakan objek mana benar atau salah [11]. Matrix prediksi akan dibandingkan dengan kelas asli dari data input, yaitu nilai aktual dan prediksi klasifikasi.

2.10. 10-Fold Cross Validation

Proses ini diulangi hingga 10 kali hingga semua record data menjadi bagian dari data uji. Proses ini juga dikenal sebagai 10-fold cross validation. Validasi ini telah terbukti memberikan kinerja algoritmik yang lebih stabil, oleh karena itu banyak digunakan oleh para peneliti [11].

3. METODE PENELITIAN

Dalam mencari model optimasi yang diusulkan pada penelitian ini untuk meningkatkan akurasi pada K-Nearest Neighbor dengan menggunakan penanganan pada missing value, normalisasi data dan dilakukan seleksi fitur, maka dilakukan pengujian penelitian dengan tahapan penelitiannya ditunjukkan pada gambar 1.



Gambar 1. Flowchart Penelitian

3.1. Pengambilan Data

Pada pengumpulan data diperoleh dari Website UCI Machine Learning Repository (<https://archive.ics.uci.edu/ml/index.php>) yaitu berupa dataset ILPD (Indian Liver Patient Dataset) tahun 2012. Dataset tersebut diolah menggunakan algoritma K-Nearest Neighbor. Dan dataset ini terdapat beberapa atribut, yaitu Age, Gender, Total pada Bilirubin, Direct Bilirubin, ALK (Alkaline Phosphotase), SGPT (Alamine Aminotransferase), SGOT (Aspartate Aminotransferase), TP (Total Protein), ALB (Albumin), A/G (Ratio Albumin and Globulin Ratio), Selector (Class). Dengan jumlah data sebanyak 583.

3.2. Penanganan Missing Value

Penanganan missing value perlu dilakukan pada data yang akan diteliti, karena adanya missing value dapat menurunkan hasil akurasi pada proses klasifikasi data. Pada penelitian ini dilakukan dua skenario penanganan missing. Pertama, dilakukan dengan mengisi data yang missing (kosong) dengan 0 dan skenario selanjutnya dengan mengganti missing value berdasarkan nilai rata-rata dari seluruh data pada atribut yang terdapat kekosongan data.

3.3. Seleksi Fitur

Tahapan selanjutnya yang akan dilakukan adalah seleksi fitur, seleksi fitur dilakukan agar algoritma memproses data lebih cepat. Metode seleksi fitur *Information Gain*, *Gain Ratio*, dan *Symmetrical Uncertainty* akan dilakukan pada penelitian ini dengan tujuan untuk mengurangi atribut yang tidak relevan pada data.

3.4. Normalisasi Data

Proses normalisasi data dilakukan untuk menyeimbangkan nilai data. Data yang akan dinormalisasi adalah data yang telah dilakukan proses penanganan missing value. Proses ini dilakukan untuk menyeimbangkan nilai data apabila data memiliki rentang nilai yang jauh dan memudahkan untuk proses klasifikasinya.

3.5. Klasifikasi KNN

Tahap klasifikasi KNN dilakukan pada data yang sudah diseleksi fitur dan normalisasi terlebih dahulu yang sudah diproses sebelumnya. Untuk penentuan nilai k yang nantinya akan dipilih sebagai model klasifikasi yang paling optimal dilakukan dengan menguji variasi nilai k menggunakan angka 1 sampai 10. Pengujian ini untuk melihat pengaruh perubahan nilai k terhadap nilai *accuracy*. Serta dilakukan juga pengujian *cross validation* untuk melihat efektifitas kinerja model.

3.6. Evaluasi dengan Confusion Matrix

Tahap evaluasi dilakukan diakhir proses penelitian. Tahap ini bermanfaat untuk melakukan pengujian model dan nilai akurasi yang dihasilkan. Dalam penelitian ini evaluasi dilakukan dengan *confusion matrix*.

4. HASIL DAN PEMBAHASAN

Dalam meningkatkan akurasi algoritma *K-Nearest Neighbor* (KNN) dengan normalisasi dan seleksi fitur untuk klasifikasi penyakit *liver* memiliki beberapa tahapan.

4.1. Penanganan Missing Value

Penanganan *missing value* dilakukan dengan mengisi data yang kosong dengan nilai 0 yang dapat dilihat pada tabel dibawah

Tabel 1. Penanganan *Missing Value = 0*

Age	Gender	TB	...	A/G	Diagnosis
45	Female	0.9	...	0	Liver
51	Male	0.8	...	0	Liver
35	Female	0.6	...	0	Non-Liver
27	Male	1.3	...	0	Non-Liver

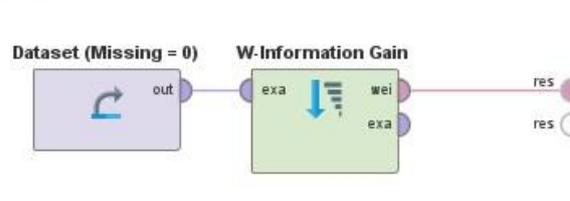
Kemudian dilakukan penanganan *missing value* lain dilakukan dengan mengisi nilai rata-rata dari seluruh atribut yang memiliki kekosongan data yang dapat dilihat pada tabel 2 berikut.

Tabel 2. Penanganan *Missing Value = Average*

Age	Gender	TB	...	A/G	Diagnosis
45	Female	0.9	...	0.95	Liver
51	Male	0.8	...	0.95	Liver
35	Female	0.6	...	0.95	Non-Liver
27	Male	1.3	...	0.95	Non-Liver

4.2. Seleksi Fitur Information Gain

Seleksi fitur dilakukan setelah melalui proses penanganan *missing value*. Dalam proses perhitungan bobot atribut dilakukan dengan menggunakan *RapidMiner Studio* dengan skema pengujian sebagai berikut



Gambar 2. Skema Seleksi Fitur Information Gain

Dari hasil pengujian dengan skema diatas diketahui bahwa atribut DB (*Direct Bilirubin*) memiliki bobot paling besar dengan nilai 0.086 yang berarti bahwa atribut tersebut memiliki pengaruh yang paling besar terhadap dataset, dan begitu seterusnya hingga atribut TP (*Total Protiens*) yang memiliki pengaruh paling kecil pada data set dengan nilai atribut 0.005 yang secara lengkap bisa dilihat pada tabel dibawah ini

Tabel 3. Hasil *Information Gain*

No	Atribut	Information Gain
1	DB	0.086
2	TB	0.085
3	Sgot Aspartate Aminotransferase	0.067
4	Alkhos Alkanine Phosphotase	0.066
5	Sgpt Alamine Aminotransferase	0.060
6	A/G	0.026
7	Age	0.021
8	ALB	0.020
9	Gender	0.005
10	TP	0.005

Pemilihan atribut dilakukan dengan menggunakan persamaan

$$\log_2 10 = 3.32$$

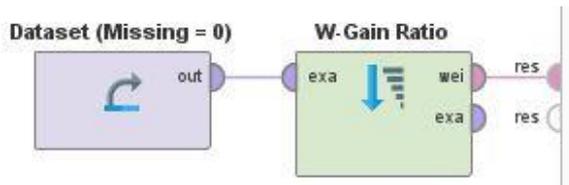
Sehingga dataset *dataset Indian Liver Patient Datasets* memiliki 10 atribut yang selanjutnya diilih 3 atribut tertinggi yang dianggap sebagai atribut paling berpengaruh berdasarkan nilai pembobotan tertinggi untuk dilakukan proses klasifikasi yang dapat dilihat pada tabel 2

Tabel 4. Atribut terpilih pada *Information Gain*

No	Atribut	Information Gain
1	DB	0.086
2	TB	0.085
3	Sgot Aspartate Aminotransferase	0.067

4.3. Seleksi Fitur Gain Ratio

Pada proses perhitungan bobot atribut dengan seleksi fitur *gain ratio* dilakukan dengan menggunakan *RapidMiner Studio* dengan skema pengujian ditunjukkan pada gambar 3



Gambar 3. Skema seleksi fitur Gain Ratio

Proses pembacaan data menggunakan operator “Retrieve” dilakukan dengan cara *drag and drop* pada data yang sudah di import. Setelah itu ditambahkan operator “Weight by Information Gain Ratio”, operator ini digunakan untuk memberikan bobot pada setiap atribut.

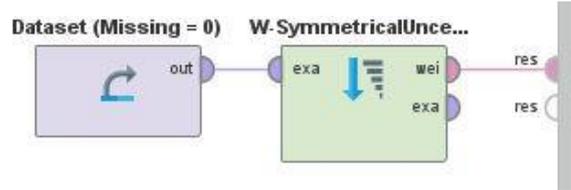
Tabel 5. Hasil seleksi fitur *Gain Ratio*

No	Atribut	Gain Ratio
1	Sgpt Alamine Aminotransferase	0.227
2	Age	0.201
3	Sgot Aspartate Aminotransferase	0.170
4	DB	0.115
5	TB	0.113
6	Alkhos Alkanine Phosphotase	0.066
7	TP	0.061
8	A/G	0.054
9	ALB	0.054
10	Gender	0.006

Atribut terpilih pada seleksi fitur *gain ratio* pada dataset *Indian Liver Patient Dataset* adalah *Sgpt Alamine Aminotransferase*, *Age* dan *Sgot Aspartate Aminotransferase* yang dapat dilihat pada Tabel 6

Tabel 6. Atribut terpilih pada *Gain Ratio*

No	Atribut	Gain Ratio
1	Sgpt Alamine Aminotransferase	0.227
2	Age	0.201
3	Sgot Aspartate Aminotransferase	0.170



Gambar 4. Skema seleksi fitur symmetrical uncertainty

4.4. Seleksi Fitur Symmetrical Uncertainty

Pada proses perhitungan bobot atribut dengan seleksi fitur *symmetrical uncertainty* dilakukan dengan menggunakan *RapidMiner Studio* dengan skema pengujian seperti Gambar 3 diatas didapat hasil seperti tabel 7 berikut

Tabel 7. Hasil seleksi fitur *Symmetrical Uncertainty*

No	Atribut	Symmetrical Uncertainty
1	TB	0.069
2	DB	0.066
3	Sgpt Alamine Aminotransferase	0.045
4	Alkhos Alkanine Phosphotase	0.044
5	Sgot Aspartate Aminotransferase	0.035
6	A/G	0.029
7	Age	0.024
8	ALB	0.016
9	Gender	0.006
10	TP	0.004

Dari hasil tersebut dapat dilihat bahwa atribut TB (*Total Bilirubin*) memiliki bobot paling besar dengan nilai 0.069 yang berarti bahwa atribut tersebut memiliki pengaruh yang paling besar terhadap dataset, dan begitu seterusnya hingga atribut TP (*Total Protiens*) yang memiliki pengaruh paling kecil pada data set dengan nilai atribut 0.004.

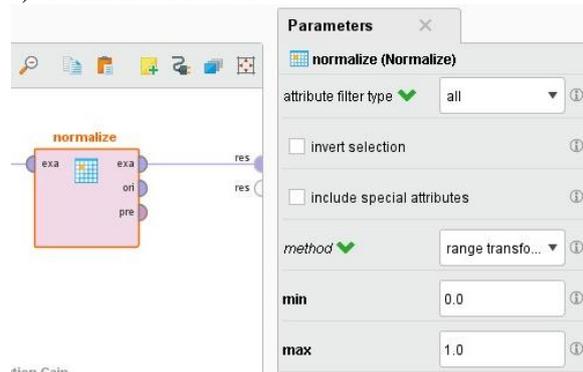
Tabel 8. Hasil seleksi fitur *symmetrical uncertainty*

No	Atribut	Information Gain
1	DB	0.069
2	TB	0.066
3	Sgpt Alamine Aminotransferase	0.045

4.5. Normalisasi

Normalisasi dilakukan pada data yang ada untuk memetakan data dalam rentang tertentu. Data yang dinormalisasi adalah data berdasarkan atribut yang dipilih pada tahap pemilihan data menggunakan seleksi fitur.

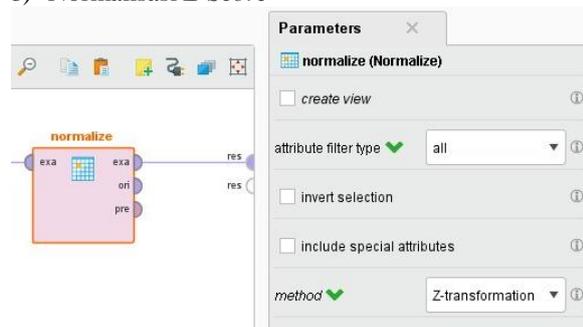
a) Normalisasi *Min-Max*



Gambar 5. Proses min-max normalization

Proses normalisasi data dilakukan dengan bantuan *RapidMiner Studio* dengan menggunakan operator “*Retrieve*” yang dilakukan dengan cara *drag and drop* data yang sudah di *import* sebelumnya. Setelah data sudah terbaca, tambahkan operator “*Select Attributes*” dan “*Normalize*” dengan parameter yang sudah terpapar pada gambar 5.

b) Normalisasi *Z-Score*



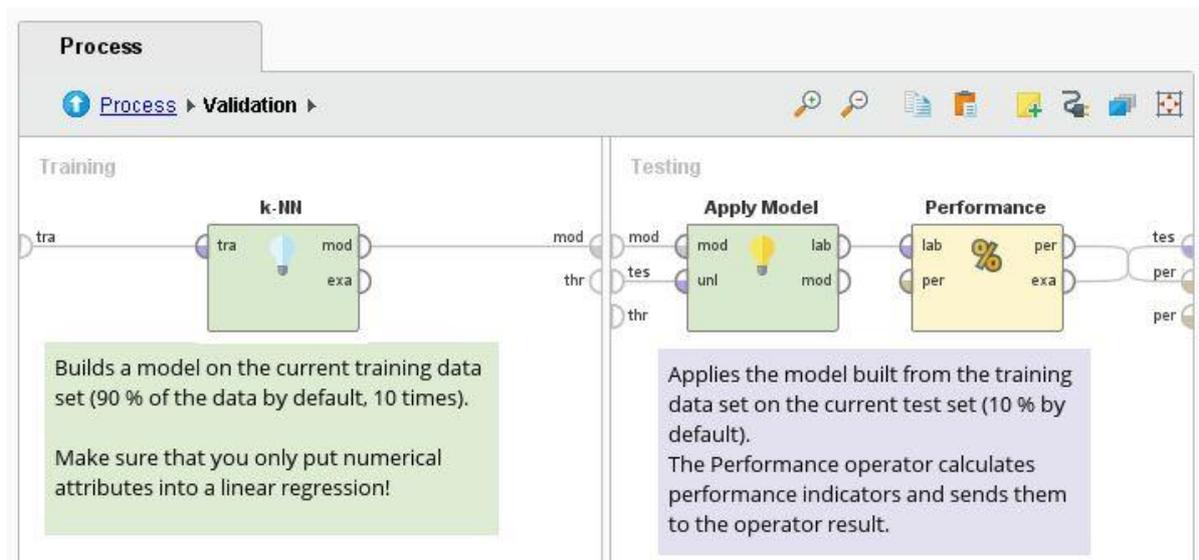
Gambar 6. Proses z-score normalization

Tahap normalisasi dilakukan pada data yang dipilih pada proses seleksi fitur. Proses normalisasi data menggunakan bantuan *RapidMiner Studio*. Pada proses *Z-Score Normalization* menggunakan *RapidMiner* ditunjukkan pada Gambar 6.

4.6. Klasifikasi *K-Nearest Neighbor (KNN)*

Pada proses klasifikasi dari *Indian Liver Patient Dataset* menggunakan algoritma *K-Nearest Neighbor* dengan menggunakan *10-Fold Cross Validation*. Pada operator “*Cross Validation*” terdapat parameter *number of folds* yang digunakan untuk mengatur berapa jumlah *folds* yang dibutuhkan, pada penelitian ini akan menggunakan 10 nilai *folds*. *10-Fold Cross Validation* artinya data akan dibagi menjadi 90% data menjadi data latih dan 10%-nya menjadi data uji. Dengan *sampling type* menggunakan *shuffled sampling*.

Didalam operator “*Cross Validation*” menggunakan operator “*k-NN*” dengan parameter nilai *k* disesuaikan dengan kebutuhan dan pada parameter pengukuran jarak dipilih *euclidean distance*. Sehingga pada operator *measure types* dipilih *NumericalMeasure* dan pada parameter *numerical measure* pilih pada pilihan *EuclideanDistance*. Operator *KNN* pada *RapidMiner* dan parameternya ditampilkan pada Gambar 7.

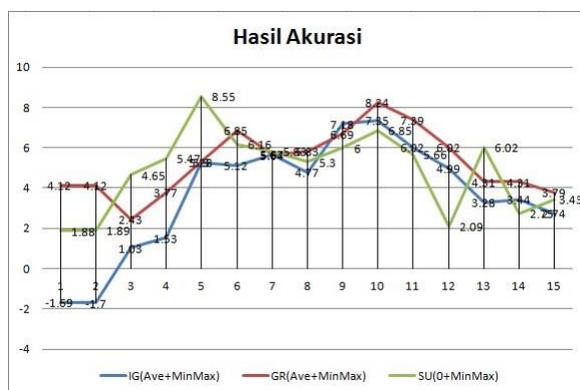


Gambar 7. Operator *KNN* pada *RapidMiner Studio*

Pada penelitian ini melakukan penanganan pada data yang mengalami kekosongan atau disebut *missing value*, normalisasi *min-max* dan *Z-Score*, serta dilakukan seleksi fitur dengan *information gain*, *gain ratio*, dan *symmetrical uncertainty* untuk mengoptimalkan kinerja algoritma *K-Nearest Neighbor* dengan mengujikan nilai *k* dari 1 sampai 10 sehingga bisa menghasilkan nilai akurasi yang lebih baik dengan tanpa dilakukan seleksi fitur. Data set yang digunakan dalam penelitian ini adalah *Indian Liver Patient Datasets* (ILPD) yang diperoleh dari *UCI Machine Learning Repository*. Data ini adalah data sekunder yang merupakan data yang digunakan dalam penelitiannya didapatkan secara tidak langsung melainkan melalui perantara. Pada data ILPD terdapat 10 atribut dan 1 atribut *class*.

Penelitian ini dilakukan untuk mencari model klasifikasi yang paling optimal untuk mengklasifikasi penyakit *liver*, dengan cara membandingkan hasil akurasi algoritma KNN setelah dilakukan penanganan *missing value*, normalisasi dan seleksi fitur dengan algoritma KNN yang tanpa menggunakan seleksi fitur untuk mengetahui pengaruh seleksi fitur pada tingkat akurasi algoritma KNN.

Missing pada data dikarenakan adanya data yang kosong pada atributnya, *missing value* pada data ini dilakukan dengan mengganti nilai yang *missing* dengan 0 dan nilai rata-rata dari atribut yang memiliki kekosongan data. Selanjutnya dilakukan normalisasi pada data, metode normalisasi menggunakan *Min-Max* dan *Z-Score* yang dapat memberikan peningkatan akurasi dengan merepresentasikan data asli dalam bentuk data baru dengan rentang nilai yang hamper seragam. Karena hal tersebut dapat menyederhanakan data sehingga proses yang dilakukan lebih cepat dan memberikan hasil optimasi yang lebih meningkat pada algoritma KNN. Selain itu dilakukan juga proses seleksi fitur, seleksi fitur yang digunakan pada penelitian ini menggunakan pembobotan *Information Gain* (IG), *Gain Ratio* (GR), dan *Symmetrical Uncertainty* (SU). Proses klasifikasi ini dilakukan dengan menggunakan nilai *k* antara 1 sampai 10.



Gambar 8. Hasil Akurasi

Penelitian ini mendapatkan hasil akurasi sesuai model yang paling optimal dapat dilihat seperti

gambar 8, pada *information gain* dan *gain ratio* didapatkan nilai paling optimal pada *missing value* yang dilakukan penanganan dengan nilai rata-rata pada data yang memiliki nilai kekosongan dan dilakukan normalisasi *min-max* juga nilai *k* = 10. Sedangkan pada *symmetrical uncertainty* didapatkan nilai optimal pada nilai *k* = 5 dan menggunakan penanganan *missing value* dengan 0 dan normalisasi *min-max* yang dapat dilihat pada gambar berikut

5. KESIMPULAN DAN SARAN

Dari hasil penelitian terkalit implementasi normalisasi dan seleksi fitur untuk meningkatkan akurasi ada algoritma *K-Nearest Neighbor* (KNN) pada *Indian Liver Patient* Dataset dapat ditarik kesimpulan sebagai berikut: Pada penelitian ini penerapan seleksi fitur dengan menggunakan pembobotan *Information Gain*, *Gain Ratio*, dan *Symmetrical Uncertainty* pada *Indian Liver Patient Dataset* menggunakan lagortima KNN tidak selalu meningkatkan hasil akurasi setelah proses klasifikasinya. Implementasi normalisasi data pada seleksi fitur juga dapat mempengaruhi hasil akurasi, normalisasi data yang tepat saat menggunakan seleksi fitur pada data ini adalah menggunakan *Min-Max Normalization*. Model klasifikasi yang didapatkan pada penelitian ini berupa model optimasi pada seleksi fitur *Information Gain* dan *Gain Ratio* dapat meningkatkan hasil akurasi apabila dilakukan pengisian data yang kosong dengan nilai rata-rata pada data yang memiliki kekosongan data dan normalisasi *Min-Max* serta menggunakan nilai *k* = 10, apa bila dengan seleksi fitur *Symmetrical Uncertainty* dapat menggunakan penanganan data kosong dengan 0 dan normalisasi data *Min-Max* serta menggunakan nilai *k* = 5. Adapun saran untuk penelitian yang ingin mengembangkan lebih lanjut adalah pada penelitian selanjutnya diharapkan dapat mengembangkan penelitian ini dengan menggunakan algoritma lain yang dapat meningkatkan hasil akurasi pada klasifikasi penyakit *liver* serta pada penelitian selanjutnya diharapkan mampu meningkatkan kinerja algoritma KNN pada data lain yang lebih besar.

DAFTAR PUSTAKA

[1] D. & K. M. A. Sugianti, "Peningkatan Akurasi Algoritma KNN dengan Seleksi Fitur Gain Ratio Untuk Klasifikasi Penyakit Diabetes Melitus," *IC-Tech*, vol. 12, no. 2, 6, 2017.

[2] P. I. Ashari, "Performance Comparising Between Naive Bayes, Decission Tree and K-Nearest Neighbor in Searching Alternative Design in an Energy Simulation Tool," *International Journal of Advanced Computer Science and Applications (IJACSA)*, vol. 4, no. 11, pp. 33-39, 2018.

[3] M. E. S. & S. R. W. Daniel, "The Analysis of Attribution Reduction of K-Nearest Neighbor (KNN) Algorithm by Using Chi-Square," *In Journal of Physics: Conference Series*, vol. 1424, no. 1, 2019.

- [4] A. Duneja and T. Puyalnithi, "Enhancing Classification Accuracy of K-Nearest Neighbours Algorithm Using Gain Ratio," *International Research Journal of Engineering and Technology (IRJET)*, vol. 4, no. 9, pp. 1385-1388, 2017.
- [5] S. & S. D. Susanto, *Pengantar Data Mining: Menggali Pengetahuan Dari Bongkahan Data.*, Yogyakarta: Andi Offset, 2018.
- [6] d. I. Binabar S. W., "Optimasi Parameter K Pada Algoritma KNN Untuk Deteksi Penyakit Kanker Payudara," *IC-Tech*, vol. 2, pp. 11-18, 2017.
- [7] L. H. R, "An Intellegent Model for Liver Disease Diagnosis Artificial Intellegence in Medicine," 2019.
- [8] A. K. B. Ginting, M. S. Lydia and M. Z. Elviwaty, "Peningkatan Akurasi Metode K-Nearest Neighbor dengan Seleksi Fitur," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 5, no. 4, pp. 1714-1719, 2021.
- [9] F. Yunita, "Penerapan Data Mining Menggunakan Algoritma K-Means Clustering Pada Penerimaan Mahasiswa Baru," *Sistemasi*, vol. 7, no. 3, p. 238, 2018.
- [10] T. Hendrawati, "KAJIAN METODE IMPUTASI DALAM MENANGANI MISSING DATA.," in *Pros. Semin. Nas. Mat. dan Pendidik. Mat*, 2018.
- [11] S. D. Indrayanti, "Peningkatan Akurasi Algoritma KNN Dengan Seleksi Fitur Gain Ratio Untuk Klasifikasi Penyakit Diabetes Mellitus.," *IC-Tech*, vol. 12, no. 2, 2017.