

KLASIFIKASI KINERJA AKADEMIK SISWA MENGGUNAKAN *NEIGHBOR WEIGHTED K-NEAREST NEIGHBOR* DENGAN SELEKSI FITUR *INFORMATION GAIN*

Rizky Adinda Azizah^{*1}, Fitra A. Bachtiar², Sigit Adinugroho³

^{1,2,3}Universitas Brawijaya, Malang

Email: ¹rizkyadindaazizah@gmail.com, ²fitra.bachtiar@ub.ac.id, ³sigit.adinu@ub.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 29 Oktober 2021, diterima untuk diterbitkan: 02 Juni 2022)

Abstrak

Kinerja akademik siswa merupakan indikator kesuksesan dari pembelajaran di sekolah. Mengukur kinerja akademik siswa dapat membantu tenaga didik mengembangkan pembelajaran yang sesuai untuk siswa sehingga meningkatkan keberhasilan pembelajaran sekolah. Kinerja akademik siswa dapat diamati melalui suatu *Learning Management System* bernama Kalboard 360 yaitu sistem yang berhubungan dengan perilaku siswa menggunakan alat pelacak aktivitas siswa yang memantau aktivitas pembelajaran. Data sekunder dari aktivitas tersebut dapat digunakan untuk mengetahui kinerja siswa dengan salah satu caranya adalah klasifikasi. Klasifikasi menggunakan metode *Neighbor Weighted K-Nearest Neighbor* dengan seleksi fitur *Information Gain* diterapkan pada penelitian ini untuk membantu klasifikasi kinerja siswa karena metode NWKNN mempunyai kelebihan memperhitungkan metode pembobotan kelas dan mengatasi data tidak seimbang. Seleksi fitur dengan *Information Gain* digunakan agar dapat mengoptimalkan hasil kerja *classifier*. Berdasarkan pengujian dan analisis penelitian, didapatkan nilai akurasi terbaik sebesar 0,604, dengan nilai *precision* adalah 0,719, nilai *recall* sebesar 0,676, dan nilai *f-measure* diperoleh adalah 0,661. Nilai tersebut dihasilkan saat menggunakan 9 fitur yaitu *VisitedResource*, *StudentAbsenceDay*, *RaisedHands*, *AnnouncementsView*, *Relation*, *ParentsAnsweringSurvey*, *Discussion*, *NationalITY*, dan *PlaceofBirth* dimana fitur tersebut memperoleh nilai *Gain* tertinggi dari urutan *Gain* keseluruhan fitur, dengan nilai *Gain* $\geq 0,1182$ dan menggunakan nilai parameter optimal yaitu nilai $E = 6$, dan nilai $K = 45$.

Kata kunci: kinerja siswa,, klasifikasi, seleksi fitur, NWKNN, information gain

CLASSIFICATION OF STUDENT ACADEMIC PERFORMANCE USING *NEIGHBOR WEIGHTED K-NEAREST NEIGHBOR* WITH *INFORMATION GAIN* AS FEATURE SELECTION METHOD

Abstract

The academic performance of students is an indicator of the success of learning in school. Measuring and understanding student performance can help for improving learning systems that are suitable for students so the success of school learning will increase. Student academic performance can be observed via Learning Management System (LMS) named Kalboard 360 dealing with student behavior through a student activity tracking device so it can monitor learning activities. In this research, the secondary data is used to determine student performance through a classification. Neighbor Weighted K-Nearest Neighbor algorithm with Information Gain method will be applied to this study to help predict student performance. NWKNN method has advantages in calculating the weight of classes and overcoming unbalanced data. Information Gain is used to optimize the classifier. Based on the research analysis, the accuracy value is 0,604, with precision value obtained is 0,719, recall value obtained is 0,676, and the f-measure value obtained is 0,661. That values is generated when using 9 features with the highest order value of all features namely *VisitedResource*, *StudentAbsenceDay*, *RaisedHands*, *AnnouncementsView*, *Relation*, *ParentsAnsweringSurvey*, *Discussion*, *NationalITY*, dan *PlaceofBirth*, which have *Gain* value $\geq 0,1182$ and using optimal parameters value, that is $E = 6$ and $K = 45$.

Keywords: : student performance, classification, feature selection, NWKNN, information gain

1. PENDAHULUAN

Salah satu cara menempuh pendidikan adalah dengan pembelajaran secara formal di sekolah.

Sekolah yang berhasil dalam pengelolaannya adalah sekolah yang membuktikan keberhasilan pada komponen masukan, proses, dan keluaran dengan ditandai oleh kualitasnya bagian-bagian tersebut

(Amran, 2015). Keberhasilan pembelajaran formal di sekolah dapat diukur dengan mengetahui kinerja akademik dari siswa yang digunakan sebagai suatu indikator penentu (Sa'adah & Ariati, 2018). Kinerja akademik siswa dapat dipantau melalui suatu sistem pembelajaran elektronik seperti *Learning Management System* (LMS). LMS adalah suatu perangkat lunak yang dimanfaatkan oleh pengajar didik sebagai sarana pembelajaran daring atau e-learning (Amiroh, 2012).

Learning Management System (LMS) bernama Kalboard 360 adalah suatu sistem yang berhubungan dengan perilaku siswa dengan menggunakan alat pelacak aktivitas siswa yang disebut experience API (xAPI) yang dapat memantau aktivitas pembelajaran (Amrieh, dkk., 2015). Data sekunder aktivitas tersebut dapat digunakan untuk prediksi atau klasifikasi kinerja akademik siswa. Menurut Amrieh, dkk., (2015) prediksi kinerja akademik siswa dapat membantu guru dalam mengurangi rasio kegagalan dengan mengambil langkah yang benar pada waktu yang tepat sehingga kinerja siswa bertambah baik, meningkatkan sistem pembelajaran yang sesuai untuk siswa, dan menghasilkan keluaran siswa yang berkualitas. Hal tersebut dapat membantu dalam peningkatan keberhasilan pembelajaran sekolah. Prediksi untuk data siswa dengan jumlah yang banyak bisa dikerjakan dengan teknik data mining yaitu klasifikasi.

Terdapat beberapa algoritme klasifikasi yang dapat diterapkan untuk keperluan prediksi antara lain *K-Nearest Neighbor* (KNN), Naive Bayes, Support Vector Machine (SVM), dan Neural Network. Penelitian terkait klasifikasi kinerja akademik telah pernah dilakukan sebelumnya oleh Jr.Raga dan Raga (2017) dengan membandingkan metode *K-Nearest Neighbor* (KNN), Linear Discriminant Analysis (LDA), Random Forest, LR, CART, BayesNet dan SVM. Menurut hasil penelitian tersebut didapatkan bahwa algoritme KNN memiliki hasil rata-rata akurasi terbaik sebesar 72,80%. Algoritma KNN. Algoritme KNN bekerja untuk menentukan kelompok pada suatu data baru dengan cara menghitung jarak paling dekat antara k data latih dan data uji. KNN merupakan salah satu algoritme yang sudah banyak digunakan dalam klasifikasi maupun prediksi dan algoritmenya cukup mudah dipahami apabila akan diimplementasikan untuk keperluan akademik sekolah oleh tenaga pendidik.

Namun, algoritme *K-Nearest Neighbor* (KNN) adalah algoritme yang tidak mempertimbangkan bobot sampel, sehingga dapat terjadi kemungkinan kesalahan pada saat klasifikasi sehingga penelitian ini akan menggunakan algoritme pengembangan KNN yaitu *Neighbor Weighted K-Nearest Neighbor* (NWKNN). Algoritme pengembangan tersebut mempunyai kelebihan dalam memperhitungkan metode pembobotan dan dapat mengatasi permasalahan terhadap data tidak seimbang (Hajizadeh, dkk., 2014). NWKNN mempunyai hasil

evaluasi yang lebih tinggi daripada algoritme KNN pada identifikasi ADHD anak usia dini dengan data yang dipakai adalah tidak seimbang dan saat nilai K besar, karena pembobotan pada NWKNN membantu data uji kelas minor bisa diidentifikasi ke kelompok yang benar (Fadilla, dkk, 2016).

Sistem klasifikasi sendiri dapat dioptimalkan dengan salah satu caranya adalah menggunakan seleksi fitur. Metode seleksi fitur dapat mengoptimalkan hasil pekerjaan dari suatu *classifier* sebab atribut yang banyak bisa mengakibatkan akurasi yang dihasilkan rendah (Chandani & Purwanto, 2015). Penelitian mengenai metode seleksi fitur telah dilakukan sebelumnya oleh Chandani & Purwanto (2015) dengan membandingkan *Backward Elimination*, *Chi Square*, *Forward Selection*, dan *Information Gain*. Hasil perbandingan tersebut didapatkan hasil rata-rata akurasi tertinggi sebesar 84,57% yang diraih oleh *Information Gain*. Berdasar dari uraian yang telah dijabarkan sebelumnya, penelitian ini akan berfokus pada klasifikasi dimana penelitian ini digunakan untuk mengklasifikasikan suatu pola kejadian untuk keberhasilan siswa dalam belajar. Hasil klasifikasi tersebut dapat digunakan sebagai dasar pengambilan keputusan atau kebijakan untuk rancangan pembelajaran selanjutnya. Penelitian akan menggunakan algoritme *Neighbor Weighted K-Nearest Neighbor* (NWKNN) dan *Information Gain* sebagai metode seleksi fitur. Diharapkan penelitian ini dapat membantu dalam melakukan klasifikasi terhadap kinerja akademik siswa.

2. METODE PENELITIAN

2.1. Pengambilan Data

Data yang digunakan untuk mengimplementasikan metode adalah data sekunder mengenai kinerja akademik siswa yang diambil dengan xAPI melalui suatu *Learning Management System* (LMS) yaitu Kalboard 360 pada penelitian yang dilakukan oleh Amrieh et. al., (2015) dan pada penelitian Amrieh et. al., (2016).

Data sekunder didapatkan melalui website Kaggle dengan alamat akses yang dapat dilihat pada link <https://www.kaggle.com/aljarah/xAPI-Edu-Data>. Terdapat 16 banyak fitur dan 3 kelas pada dataset yakni High, Middle, dan Low. Dalam penelitian ini akan menggunakan 3 kelas tersebut untuk klasifikasi kinerja akademik siswa.

2.2. Kinerja Akademik Siswa

Masing-masing anak / siswa memiliki kinerja yang berbeda-beda. Pengelompokan terhadap kinerja akademik siswa bertujuan untuk memberikan perlakuan kepada siswa berdasarkan kecakapan dalam bidang akademik serta membantu tiap siswa yang membutuhkan perhatian lebih atau anak mana yang bisa diajak berasumsi dulu untuk kemudian diberi pertanyaan (Huriah, 2018).

2.3. Learning Management System (LMS)

Learning Management System (LMS) merupakan sistem perangkat lunak yang berfungsi mengotomatiskan pekerjaan administrasi, pelacakan, pelaporan aktivitas pelatihan beserta dokumentasi. LMS biasa digunakan oleh pendidik seperti guru, dosen dan instruktur. Sistem ini bermanfaat karena membantu manajemen pembelajaran dan menolong tenaga pendidik dan anak didik untuk berkomunikasi di mana saja dan kapan saja (Amiroh, 2012).

2.4. Transformasi Data

Transformasi data merupakan suatu langkah untuk mengubah data menjadi data yang dapat diolah dengan metode data mining. Tahapan ini digunakan untuk melakukan proses pada *Information Gain*. Salah satunya diskritisasi dengan metode Equal Width Binning untuk mengubah fitur numerik menjadi fitur kategoris yang mencakup pengurutan fitur kontinyu kemudian membagi domain fitur yang diamati ke dalam suatu interval k dengan lebar yang sama (δ) dengan titik potong $k + 1$ (DIMIC, dkk., 2018). Persamaan (1) merupakan cara dalam melakukan Equal Width Binning.

$$\delta = \frac{(a_{max} - a_{min})}{k} \quad (1)$$

Dimana k adalah nilai interval, δ adalah nilai lebar dari fitur kontinyu yang terbagi, a_{max} adalah nilai maksimum dari fitur kontinyu, dan a_{min} = nilai minimum dari fitur kontinyu.

2.5. Seleksi Fitur Information Gain

Information Gain adalah metode seleksi fitur yang masuk ke dalam kategori metode filter yang dapat menentukan fitur-fitur yang relevan dari sekumpulan fitur suatu dataset. *Information Gain* bekerja dengan mengukur nilai entropy tiap fitur sebelum diperingkat sesuai dengan relevansinya dalam menentukan kelas-kelas yang berbeda (Osanaie, et al., 2016). Proses seleksi fitur dengan *Information Gain* diawali oleh perhitungan nilai entropy kemudian menghitung nilai Gain tiap fitur yang bisa dilakukan dengan Persamaan (2) – Persamaan (4) (Maulana & Al Karomi, 2015):

$$Info(D) = - \sum_{i=1}^n p_i \log_2(p_i) \quad (2)$$

Dimana D merupakan himpunan kasus suatu dataset atau suatu fitur, n adalah banyaknya kategori atau kelas di dalam data, dan p_i adalah proporsi dari D_j terhadap D

$$Info_A(D) = - \sum_{j=1}^v \frac{|D_j|}{|D|} \times I(D_j) \quad (3)$$

$$Gain(A) = Info(D) - Info_A(D) \quad (4)$$

Dimana v merupakan banyak partisi fitur A , $|D_j|$ adalah jumlah kasus pada partisi ke j dalam fitur A , $|D|$ ialah jumlah kasus dalam D , selanjutnya $I(D_j)$ merupakan total entropy dalam partisi pada fitur A . $Gain(A)$ pada persamaan di atas adalah Informasi fitur A , $Info(D)$ merupakan total entropy sebelum pemisahan sedangkan $Info_A(D)$ adalah entropy fitur A .

2.6. Neighbor Weighted K-Nearest Neighbor (NWKNN)

Neighbor Weighted K-Nearest Neighbor (NWKNN) adalah peningkatan dari kerja algoritme *K-Nearest Neighbor* (KNN) sebagai upaya untuk mengatasi data tidak seimbang dengan adanya banyak kelas mayoritas pada suatu data yang dapat menyebabkan penurunan akurasi (Indriati & Ridok, 2016). Kelas mayoritas akan diberikan bobot lebih kecil daripada bobot yang akan diberikan pada bobot mayoritas (Yudha, dkk., 2018). Secara garis besar perhitungan metode KNN dan NWKNN hampir serupa dimana pertama kali adalah menentukan nilai K (banyak tetangga terdekat) kemudian menghitung dan mengurutkan jarak kedekatan antar data. Hal yang berbeda dari NWKNN adalah adanya nilai eksponen serta perhitungan bobot seperti pada Persamaan (5) dan perhitungan skor yang dapat dilihat pada Persamaan (6).

$$Weight_i = \frac{1}{\frac{Num(C_i^d)}{\min\{Num(C_j^d) | j=1, \dots, K\}}^{1/exp}} \quad (5)$$

$$Skor(X, C_i) = Weight_i * \sum d_j NWKNN(x)((d(i, j) * \delta(d_j, C_i))) \quad (6)$$

Dimana *Weight i* merupakan bobot untuk kelas ke- i , $Num(C_i^d)$ adalah jumlah data latih d pada kelas ke- i , $Num(C_j^d)$ merupakan jumlah data latih d pada kelas ke- j , kemudian j merupakan kategori semua kelas pada data latih, lalu exp merupakan nilai eksponen lebih dari 1, untuk $\delta(d_j, C_i)$ akan bernilai 1 apabila kelas jarak pada data latih ke- j merupakan anggota himpunan C_i dan bernilai 0 bila kelas jarak bukan anggota himpunan C_i , sedangkan $d(i, j)$ ialah jarak data uji dan data latih.

Menghitung nilai kedekatan atau jarak data uji dan data latih dengan dataset yang memiliki atribut tipe campuran bisa dilakukan dengan Persamaan (7) dan Persamaan (8):

$$d(i, j) = \frac{\sum_{f=1}^p \delta_{ij}^{(f)} d_{ij}^{(f)}}{\sum_{f=1}^p \delta_{ij}^{(f)}} \quad (7)$$

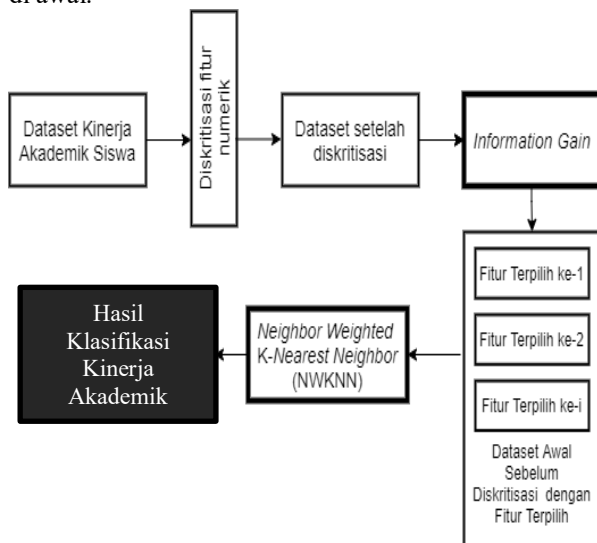
$$d_{ij}^{(f)} = \frac{|x_{if} - x_{jf}|}{\max_h x_{hf} - \min_h x_{hf}} \quad (8)$$

Pada persamaan tersebut, $\delta_{ij}^{(f)}$ akan bernilai 0 jika x_{if} atau x_{jf} *missing* atau $x_{if} = x_{jf} = 0$, jika tidak

$\delta_{ij}^{(f)}$ bernilai 1. Jika f adalah tipe data numerik maka menggunakan Persamaan (7). Jika f adalah nominal maka $d_{ij}^{(f)}$ bernilai 0 jika $x_{if} = x_{jf}$; jika tidak $d_{ij}^{(f)}$ bernilai 1.

3. PERANCANGAN SISTEM

Proses implementasi metode bisa diamati pada gambar 1. Tahap yang pertama dilakukan adalah memasukkan dataset yang akan diproses sistem untuk dapat diklasifikasikan. Dataset dibagi menjadi 2 bagian yakni sebanyak 80% data latih dan 20% data uji yang digunakan sebagai data validasi. Data latih sebanyak 80% akan digunakan untuk mencari parameter terbaik dan jumlah fitur terbaik pada pengujian dengan menggunakan *5-fold cross validation*. Setelah dataset dimasukkan, sistem kemudian akan melakukan tahapan seleksi fitur dengan algoritme *Information Gain* dengan melakukan diskritisasi terlebih dahulu. Setelah tahap seleksi fitur selesai, lalu data baru yang didapat dengan fitur yang telah dipilih diproses dengan metode *Neighbor Weighted K-Nearest Neighbor* (NWKNN). Proses NWKNN akan menghasilkan klasifikasi dari data uji kinerja akademik siswa, dengan melakukan validasi terhadap metode pada sistem menggunakan 20% data latih yang telah dibagi di awal.



Gambar 1. Proses implemmtasi metode

3.1. Rancangan Pengujian

Penelitian ini akan melakukan empat macam pengujian yaitu pengujian pengaruh seleksi fitur, pengujian parameter E (eskponen), pengujian parameter K (banyak tetangga terdekat), dan pengujian parameter terbaik. Pengujian untuk melihat pengaruh seleksi fitur dilakukan dengan melihat hasil nilai evaluasi yang dihasilkan berdasarkan suatu batasan atau threshold yang telah ditetapkan yaitu menggunakan batasan ranking. Pada pengujian parameter dikerjakan dengan uji coba kemungkinan-kemungkinan parameter nilai K (banyak tetangga

terdekat) dan nilai E (eksponen). Uji coba dilakukan dengan rentang nilai parameter tertentu untuk dilihat hasil evaluasinya sehingga di akhir penelitian dapat diketahui parameter K dan E terbaik. Sedangkan uji coba dengan menggunakan parameter terbaik bertujuan supaya di akhir penelitian dapat diketahui rata-rata evaluasi yang diperoleh dari sistem yang dibangun. Evaluasi yang digunakan pada hasil pengujian adalah nilai akurasi, *recall*, *precision*, dan *f-measure* dengan menggunakan *K-Fold Cross Validation*.

3.2. Metode Evaluasi

Metode evaluasi yang akan digunakan adalah dengan menggunakan *K-fold cross validation* dan menggunakan teknik pengukuran akurasi, *precision*, *recall* dan *f-measure*. *K-fold cross validation* merupakan satu prosedur standar untuk melakukan evaluasi dari kinerja suatu algoritme klasifikasi. Baris pada dataset secara acak dibagi ke dalam k lipatan-lipatan data dengan jumlah yang sama dimana setiap lipatan akan mendapat kesempatan sebagai data uji dan data latih (Wong & Yang, 2017). Nilai k pada *k-fold* yang kurang dari 5 dapat menimbulkan permasalahan (Jung, 2018). Selain menggunakan *K-fold cross validation* beberapa metode pengukuran yang umum dipakai untuk mengukur kinerja sistem adalah dengan akurasi, *recall*, *precision*, dan *f-measure*. Menghitung akurasi dapat menggunakan Persamaan (9):

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi benar}}{\text{Jumlah data uji}} \quad (9)$$

Precision, *recall*, dan *f-measure* dicari dengan perhitungan macroaveraged. Macroaveraged merupakan perhitungan lokal *recall*, *precision*, dan *f-measure* untuk masing-masing kategori kemudian dihitung secara keseluruhan melalui perhitungan rerata perolehan *recall*, *precision*, serta *f-measure* dari tiap kategori yang ada (Ridok & Latifah, 2015). Menghitung *precision*, *recall*, dan *f-measure* secara lokal dapat dilihat pada Persamaan (10), (11), dan (12).

$$F = \frac{2 \times P \times R}{P + R} \quad (10)$$

$$P = \frac{TP}{TP + FP} \quad (11)$$

$$R = \frac{TP}{TP + FN} \quad (12)$$

Dimana F adalah *f-measure*, P adalah *precision*, R adalah *recall*, TP adalah true positif, FP adalah false positif, dan FN adalah false negative. Perhitungan macroaveraged untuk *recall*, *precision*, dan *f-measure* global masing-masing dapat dilihat pada persamaan (13), (14), dan (15).

$$\text{MacroPrecision} = \frac{1}{Q} \sum_{k=1}^Q P_k \quad (13)$$

$$\text{MacroRecall} = \frac{1}{Q} \sum_{k=1}^Q R_k \quad (14)$$

$$MacroFmeasure = \frac{1}{Q} \sum_{k=1}^Q F_k \quad (15)$$

Pada persamaan, Q adalah total entitas kategori sedangkan F_k, R_k, P_k merupakan nilai F-Measure, Recall, dan Precision yang telah dihitung dari masing-masing kategori ke-k.

4. HASIL DAN PEMBAHASAN

4.1. Pengujian Pengaruh Seleksi Fitur Information Gain

Pada pengujian seleksi fitur *Information Gain* akan menggunakan n -jumlah fitur sebagai *threshold* atau batasan ranking berdasarkan pada penelitian yang dilakukan oleh Sari (2016) yang memakai batas ranking dengan tetapan nilai n (banyak fitur). Menguji jumlah fitur yang digunakan pada saat proses klasifikasi juga berguna agar memperoleh dan mengetahui jumlah dan fitur terbaik apa saja pada data yang jika digunakan dalam pengklasifikasian dapat memberi akurasi optimal.

Fitur-fitur yang diujikan diambil berdasarkan hasil *Information Gain* yang telah terurut dari nilai *Gain* paling besar ke nilai paling kecil, lalu fitur-fitur yang ada dibawah n -jumlah fitur yang telah ditentukan akan dieliminasi, dimulai dari fitur dengan nilai *Gain* terbesar dari penggunaan jumlah fitur = 1 dan dilakukan bertahap hingga jumlah fitur yang digunakan adalah jumlah fitur = 16. Tiap tahapan, jumlah fitur akan ditambah satu. Nilai K dan nilai E telah ditetapkan di awal yakni $K = 15$ dan $E = 4$. Setiap fitur akan diulang sebanyak jumlah k -fold yang telah ditentukan yaitu k -fold=5 dan hasilnya dirata-rata. Urutan ranking fitur dari nilai *Gain* terbesar ke terkecil ditampilkan di dalam Tabel 1. Hasil pengujian dapat diamati pada Tabel 2.

Berdasarkan hasil pada Tabel 2, nilai rata-rata akurasi, *recall* dan *f-measure* tertinggi di dapatkan pada saat menggunakan 9 buah fitur dari urutan turun nilai *Gain*. Hasil pengujian terhadap penggunaan jumlah fitur ditunjukkan pada Tabel 2.

Sembilan fitur tersebut antara lain adalah *VisITedResource*, *StudentAbsenceDay*, *Raisedhands*, *AnnouncementsView*, *Relation*, *ParentsAnsweringSurvey*, *Discussion*, *Nationality* dan *PlaceofBirth* dengan nilai $Gain \geq 0,1182$. Fitur *Raisedhands*, *VisITedResources*, *AnnouncementsView* dan *Discussion* merupakan fitur-fitur numerik sedangkan fitur *Relation*, *StudentAbsenceDay*, *ParentsAnsweringSurvey*, *Nationality*, dan *PlaceofBirth* merupakan fitur kategoris. Dapat dikatakan fitur-fitur tersebut memberi pengaruh pada kinerja akademik siswa.

Rata-rata tertinggi nilai akurasi, *precision* dan *f-measure* berturut-turut adalah sebesar 0,732, 0,736 dan 0,731. Nilai *precision* tertinggi didapat ketika menggunakan 8 buah fitur dengan rata-rata *recall* sebesar 0,751, sedangkan dengan 9 fitur rata-rata *precision* adalah 0,753, sehingga perbedaan tersebut

tidak cukup berpengaruh. Pada saat jumlah fitur=1 hasil nilai rata-rata terendah untuk nilai akurasi, *precision*, *recall* dan *f-measure* dengan masing-masing rata-rata yang didapatkan adalah 0,498, 0,476, 0,476, dan 0,459.

Tabel 2 Urutan Turun Tiap Fitur Berdasarkan Perolehan Nilai *Gain*

Nomor Urutan/ Ranking Fitur	Nama Fitur	Nilai <i>Gain</i>
1	VisitedResource	0,4055
2	StudentAbsenceDay	0,3851
3	Raisedhands	0,3815
4	AnnouncementsView	0,2919
5	Relation	0,1816
6	ParentsAnsweringSurvey	0,1360
7	Discussion	0,1325
8	Nationality	0,1194
9	PlaceofBirth	0,1182
10	ParentsSatisfaction	0,0909
11	gender	0,0712
12	GradeID	0,0623
13	Topic	0,0339
14	semester	0,0178
15	StageID	0,0069
16	SectionID	0,0064


Tabel 1 Hasil Pengujian Penggunaan Jumlah Fitur

Jumlah Fitur	Nilai Rata-Rata			
	Akurasi	Precision	Recall	Precision
1	0,498	0,476	0,476	0,459
2	0,638	0,621	0,63	0,615
3	0,659	0,659	0,669	0,652
4	0,69	0,694	0,683	0,679
5	0,698	0,709	0,713	0,694
6	0,706	0,716	0,728	0,708
7	0,721	0,729	0,74	0,721
8	0,732	0,734	0,753	0,729
9	0,732	0,736	0,751	0,731
10	0,688	0,693	0,713	0,681
11	0,695	0,693	0,728	0,693
12	0,714	0,714	0,746	0,712
13	0,708	0,716	0,746	0,708
14	0,698	0,707	0,732	0,697
15	0,68	0,683	0,715	0,679
16	0,654	0,666	0,699	0,652

Perbandingan penggunaan seleksi fitur dan tanpa seleksi fitur dapat dilihat pada Gambar 2. Tiap fitur akan diperingkat dari hasil nilai *Gain* yang didapat pada saat proses perhitungan dengan metode *Information Gain*. Makin tinggi nilai *Gain*, maka semakin relevan fitur tersebut terhadap studi kasus. Ketika menggunakan jumlah fitur yang semakin banyak menyebabkan penurunan nilai karena nilai *Gain* kecil yang tidak begitu relevan juga digunakan pada saat proses klasifikasi.

Menggunakan fitur yang terlalu banyak akan meningkatkan dimensi data yang juga akan menurunkan hasil evaluasi yang diperoleh. Tetapi,

jumlah fitur yang terlalu sedikit juga berpengaruh pada hasil klasifikasi, karena jika fitur yang digunakan sedikit, maka informasi yang bisa digunakan untuk klasifikasi juga kurang sehingga dapat menyebabkan kesalahan pada saat hasil kelas. Percobaan ini juga membuktikan, menggunakan seluruh fitur yang ada menghasilkan hasil evaluasi yang lebih rendah daripada ketika memakai fitur-fitur terpilih dari metode seleksi fitur dimana fitur tersebut berjumlah 9 dengan *Gain* tertinggi yang memiliki nilai lebih dari sama dengan 0,1182.



Gambar 2. Grafik Perbandingan Hasil Klasifikasi dengan Seleksi Fitur dan Tanpa Seleksi Fitur


4.2. Pengujian Nilai Parameter E

Hasil pengujian Nilai Parameter E dapat dilihat pada Tabel 3. Pecobaan nilai *E* yang digunakan pada pengujian terletak pada rentang 2 sampai dengan 20 yaitu 2, 4, 6, 8, 10, 12, 14, 16, 18, dan 20. Jumlah fitur yang digunakan sebanyak 9 buah fitur yang didapat dari hasil terbaik pengujian sebelumnya dan dengan nilai $K = 15$. Nilai *k-fold* yang ditetapkan adalah $k\text{-fold}=5$ dari 80% data latih yang kemudian hasil evaluasi tiap fold akan dirata-rata dan dijadikan sebagai hasil nilai evaluasi. Nilai terbaik yang didapat yakni ketika $E=6$ dengan nilai rata-rata akurasi terbesar adalah 0,732, rata-rata *recall* terbesar bernilai 0,75, dan nilai rata-rata *f-measure* tertinggi adalah 0,732. Nilai *precision* tertinggi diperoleh pada $E=4$ walaupun nilainya tidak begitu jauh dengan $E=6$.

Tabel 3 Hasil Pengujian Nilai Parameter E

Nilai E	Nilai Rata-Rata			
	Akurasi	Precision	Recall	F-Measure
2	0,716	0,721	0,744	0,716
4	0,732	0,736	0,751	0,731
6	0,732	0,735	0,75	0,732
8	0,732	0,735	0,75	0,732
10	0,726	0,731	0,744	0,726
12	0,724	0,729	0,741	0,724
14	0,726	0,73	0,743	0,726
16	0,726	0,73	0,743	0,726
18	0,726	0,73	0,743	0,726
20	0,726	0,73	0,743	0,726

Pada hasil pengujian dapat dilihat bahwa semakin besar nilai *E* maka hasil akurasi, *precision*, *recall*, dan *f-measure* akan semakin stabil walau dengan adanya sedikit penurunan dan kenaikan di beberapa nilai *E* tertentu, seperti pada $E=10$ yang mengalami penurunan dan naik dengan stabil hingga ke $E=20$ yang mempunyai nilai *E* dengan *f-measure* terbaik. Grafik batang hasil pengujian dapat dilihat pada Gambar 3.



Gambar 3. Grafik Hasil Pengujian Parameter E

Nilai eksponen digunakan untuk menentukan besar bobot dari suatu kelas ketika proses klasifikasi. Mengubah nilai eksponen juga membuat nilai bobot berubah. Bobot yang didapat akan mempengaruhi nilai skor akhir yang didapat untuk menentukan hasil klasifikasi. Nilai bobot digunakan untuk mengatasi permasalahan adanya kelas tidak seimbang dengan memperkecil nilai skor kelas mayoritas dan memperbesar skor kelas minoritas. Hal ini membuktikan bahwa nilai eksponen cukup memiliki pengaruh keakuratan sistem.


4.3. Pengujian Nilai Parameter K

Pengujian nilai *K* menggunakan nilai 5, 10, 15, 20, 25, 30, 35, 40, 45, dan 50. Jumlah fitur dan Nilai parameter *E* yang digunakan adalah hasil terbaik rata-rata *f-measure* pada pengujian sebelumnya yaitu jumlah fitur=8 dan $E = 18$. Pengujian dilakukan sebanyak $k\text{-fold}=5$ dari 80% data latih yang digunakan dan hasil tiap fold akan dirata-rata. Hasil pengujian dapat dilihat pada Tabel 4.

Jika dilihat dari hasil yang diperoleh pada Tabel 4, $K=45$ memiliki nilai yang paling tinggi untuk masing-masing hasil rata-rata baik hasil akurasi, *precision*, *recall*, dan *f-measure*. Perolehan nilai rata-rata akurasi tertinggi yaitu sebesar 0,747, rata-rata *precision* tertinggi berada pada nilai 0,754, hasil rata-rata nilai *recall* terbaik adalah 0,755, dan nilai rata-rata *f-measure* paling besar didapat dengan nilai 0,738. Pada Gambar 4 dapat dilihat grafik hasil pengujian parameter *K* yang dapat diamati.

Tabel 4 Hasil Pengujian Nilai Parameter K

Nilai K	Nilai Rata-Rata			
	Akurasi	Precision	Recall	F-Measure
5	0,68	0,69	0,7	0,685
10	0,695	0,702	0,718	0,695
15	0,732	0,735	0,75	0,732
20	0,719	0,729	0,739	0,72
25	0,727	0,74	0,748	0,727
30	0,732	0,751	0,745	0,729
35	0,726	0,74	0,74	0,722
40	0,727	0,733	0,732	0,715
45	0,747	0,754	0,755	0,738
50	0,716	0,729	0,734	0,71



■ Akurasi ■ Precision ▨ Recall ■ F-Measure

Gambar 4. Grafik Hasil Pengujian Parameter K

Dilihat dari Gambar 4, nilai K yang terlalu kecil dan besar mengakibatkan menurunnya keakuratan sistem walau menurun dengan tidak stabil. Pada nilai K yang besar, semakin banyaknya nilai tetangga atau nilai K yang digunakan, maka kemungkinan masuknya kelas minoritas ke dalam kelas mayoritas pada hasil klasifikasi semakin besar. Hal tersebut karena pada proses klasifikasi terdapat perhitungan dan pengurutan nilai jarak, dimana semakin mirip antara kedua data maka akan semakin kecil jarak diantara keduanya. Posisi urutan jarak semakin ke bawah menandakan kemiripan antar data semakin kecil. Nilai K yang kecil juga tidak menentukan bahwa hasil klasifikasi akan lebih akurat, karena pada urutan jarak dapat terjadi kondisi dimana kelas lain yang memiliki nilai jarak yang lebih dekat berada pada urutan paling atas maka kelas lain tersebut bisa keluar sebagai hasil klasifikasi.


4.4. Pengujian Parameter Terbaik

Pengujian parameter terbaik ini ditujukan untuk mengetahui hasil rata-rata evaluasi yang didapatkan dari pengujian sistem. Pengujian ini dilakukan dengan menggunakan hasil terbaik dari pengujian sebelumnya yaitu menggunakan jumlah fitur = 9, nilai $E = 6$, dan nilai $K = 6$. Dataset berjumlah 480 data akan dibagi dengan perbandingan data latih dan data uji 80%:20% yang artinya 96 data uji dan sisanya 384 data latih. Hasil dapat dilihat pada Tabel 5.

Tabel 5 Hasil Pengujian Parameter Terbaik

	Akurasi	Precision	Recall	F-Measure
Hasil	0,604	0,719	0,676	0,661

Hasil pengujian pada 20% data uji dan 80% data latih dengan menggunakan parameter terbaik yakni jumlah fitur=9, nilai $E=6$ dan nilai $K=45$ mendapatkan hasil evaluasi dimana nilai f -measure diperoleh adalah 0,661, nilai akurasi adalah 0,604, nilai $precision$ adalah 0,719 dan nilai $recall$ didapat adalah 0,676. Hal tersebut bisa terjadi karena pada saat klasifikasi dengan *Neighbor Weighted K-Nearest Neighbor* (NWKNN) menggunakan *Information Gain* terdapat proses perhitungan skor yang dikalikan dengan bobot. Ketika proses perhitungan skor, kelas mayor memiliki skor lebih besar daripada kelas minor, tetapi ketika sudah dikalikan dengan bobot maka kelas minor dapat memperoleh hasil skor yang lebih besar daripada kelas mayor, sehingga menyebabkan kelas minor dapat keluar sebagai hasil klasifikasi walaupun kelas aktual atau kelas sesungguhnya adalah kelas mayor. Grafik pengujian parameter terbaik dapat dilihat pada Gambar 5.



■ Akurasi ■ Precision ▨ Recall ■ F-Measure

Gambar 5. Grafik Hasil Pengujian Parameter Terbaik

5. KESIMPULAN

Bersumber dari hasil penelitian dan pengujian yang telah dilakukan dapat disimpulkan bahwa seleksi fitur dengan algoritme *Information Gain* dapat membantu dalam memilih fitur-fitur yang akan digunakan dalam proses klasifikasi dan menghasilkan nilai evaluasi yang lebih baik daripada tidak menggunakan seleksi fitur sama sekali. Penggunaan fitur yang terlalu sedikit dan terlalu banyak dapat memberikan hasil evaluasi yang rendah. Hasil evaluasi terbaik diperoleh ketika jumlah fitur=9 dari total fitur dengan perolehan nilai $Gain$ paling tinggi berdasarkan dari hasil pengurutan nilai $Gain$ dimana nilai $Gain \geq 0,1182$.

Jumlah fitur=9 fitur tertinggi dari fitur keseluruhan, dengan fitur-fitur yang digunakan adalah *StudentAbsenceDay*, *RaisedHands*, *AnnouncementsView*, *Relation*, *ParentsAnsweringSurvey*, *Discussion*, *Nationality*, dan *PlaceofBirth*. Fitur-fitur tersebut dapat memberikan pengaruh optimal dan melakukan klasifikasi kinerja akademik siswa dengan baik.

Pada pengujian parameter yaitu parameter E , nilai E semakin besar akan semakin stabil. Nilai parameter E yang menghasilkan nilai optimal adalah $E=6$. Sedangkan saat pengujian nilai parameter K pada klasifikasi kinerja akademik siswa nilai K yang terlalu kecil maupun terlalu besar memberikan hasil evaluasi yang semakin kecil. Nilai parameter K optimal didapat ketika $K=45$. Hasil evaluasi dengan menggunakan parameter terbaik antara lain jumlah fitur=9, nilai $E=6$, dan nilai $K=45$ adalah sebesar 0,604 untuk nilai rata-rata akurasi, nilai rata-rata *precision* diperoleh adalah 0,719, nilai rata-rata *recall* sebesar 0,676, dan nilai rata-rata *f-measure* didapat adalah 0,661.

Kontribusi penelitian ini adalah mengukur kinerja siswa melalui suatu Learning Management System bernama Kalboard 360. Hasil penelitian menghasilkan 9 fitur terbaik yang menghasilkan klasifikasi terbaik dari 16 fitur pada data sekunder yaitu *VisitedResource*, *StudentAbsenceDay*, *RaisedHands*, *AnnouncementsView*, *Relation*, *ParentsAnsweringSurvey*, *Discussion*, *NationalITY*, dan *PlaceofBirth*.

Penelitian ini masih terdapat kekurangan sehingga pada penelitian selanjutnya dapat mempertimbangkan untuk menggunakan kombinasi dari algoritme seleksi fitur yang lain selain metode *Information Gain* dan bisa menerapkan algoritme klasifikasi lain yang lebih sesuai untuk menangani dataset yang memiliki atribut-atribut dengan sifat berbeda/*mixed attribute dataset*.

DAFTAR PUSTAKA

- AMIROH, 2012. Kupas Tuntas Membangun E-Learning dengan Learning Management System Moodle Versi 2. 1st ed. Sidoarjo: Genta Group Production.
- AMRAN, 2015. Faktor Penentu Keberhasilan Pengelolaan Satuan Pendidikan. *Jurnal Manajer Pendidikan*, 9(2), pp. 185-196.
- AMRIEH, E. A., HAMTINI, T. & ALJARAH, I., 2015. Preprocessing and Analyzing Educational Data Set Using X-API for Improving Student's Performance. *Jordan, IEEE*, pp. 1-5.
- AMRIEH, E. A., HAMTINI, T. & ALJARAH, I., 2016. Mining Educational Data to Predict Student's academic Performance using Ensemble Methods. *International Journal of Database Theory and Application*, 9(8), pp. 119-136.
- CHANDANI, V. & PURWANTO, R. S. W., 2015. Komparasi Algoritma Klasifikasi Machine Learning dan Feature Selection pada Analisis Sentimen Review Film. *Journal of Intelligent System*, 1(1), pp. 55-59.
- DIMIC, G., RANCIC, D., MILENTIJEVIC, I. & SPAEVIC, P., 2018. Improvement of the Accuracy of Prediction Using Unsupervised Discretization Method: Educational Data Set Case Study. *Tehnički vjesnik*, 25(2), pp. 407-414.
- FADILLA, P. N., INDRIATI & RATNAWATI, E. D., 2016. Identifikasi Jenis Attention Deficit Hyperactivity Disorder (ADHD) Pada Anak Usia Dini Menggunakan Metode Neighbor Weighted K-Nearest Neighbor (NWKNN). *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 3(3), pp. 194-200.
- HAJIZADEH, Z., TAHERI, M. & JAHROMI, M. Z., 2014. Nearest Neighbor Classification with Locally Weighted Distance for Imbalanced Data. *International Journal of Computer and Communication Engineering*, 3(2), pp. 81-86.
- HAN, J., KAMBER, M. & PEI, J., 2012. *Data Mining: Concepts and Techniques*. 3rd ed. Waltham: Elsevier Inc..
- HURIAH, D. T., 2018. *Metode Student Center Learning: Aplikasi pada Pendidikan Keperawatan*. 1st ed. Jakarta: Prenamedia Group.
- INDRIATI & RIDOK, A., 2016. Sentiment Analysis For Review Mobile Applications Using Neighbor Method Weighted K-Nearest Neighbor (Nwkn). *Journal of Environmental Engineering & Sustainable Technology*, 3(1), pp. 23-32.
- JR RAGA, R. C. & RAGA, J. D., 2017. Monitoring Class Activity and Predicting Student Performance Using Moodle Action Log Data. *International Journal of Computing Sciences Research*, 1(3), pp. 1-16.
- JUNG, Y., 2018. Multiple Predicting K-fold Cross-Validation for Model Selection. *Journal of Nonparametric Statistics*, 30(1), pp. 197-215.
- MAULANA, M. R. & AL KAROMI, M. A., 2015. Information Gain Untuk Mengetahui Pengaruh Atribut Terhadap Klasifikasi Persetujuan Kredit. *Jurnal Litbang Kota Pekalongan*, Volume 9, pp. 113-123.
- OSANAIYE, O. et al., 2016. Ensemble-based multi-filter feature selection method for DDoS detection in cloud computing. *EURASIP Journal on Wireless Communications and Networking*, 2016(1), pp. 1-10.
- RIDOK, A. & LATIFAH, R., 2015. Klasifikasi Teks Bahasa Indonesia Pada Corpus Tak Seimbang Menggunakan NWKNN. *Proceedings Konferensi Nasional Sistem dan Informatika (KNS&I)*. Bali, STMIK STIKOM.
- SA'ADAH, U. & ARIATI, J., 2018. Hubungan Antara Student Engagement (Keterlibatan Siswa) Dengan Prestasi Akademik Mata Pelajaran Matematika Pada Siswa Kelas XI

- SMA Negeri 9 Semarang. Jurnal Empati, 7(1), pp. 69-75.
- SARI, B. N., 2016. Implementasi Teknik Seleksi Fitur Information Gain Pada Algoritma Klasifikasi Machine Learning Untuk Prediksi Performa Akademik Siswa. Yogyakarta, STMIK AMIKOM Yogyakarta.
- WONG, T.-T. & YANG, N.-Y., 2017. Dependency Analysis of Accuracy Estimates in k-Fold Cross Validation. IEEE Transactions on Knowledge and Data Engineering , 29(11), pp. 2417 - 2427.
- YUDHA, B. L., MUFLIKHAH, L. & WIHANDIKA, R. C., 2018. Klasifikasi Risiko Hipertensi Menggunakan Metode Neighbor Weighted K-Nearest Neighbor (NWKNN). Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, 2(2), pp. 897-904.

Halaman ini sengaja dikosongkan