

PENERAPAN EDUCATIONAL DATA MINING PADA PREDIKSI KINERJA SISWA DI KELAS: STUDI LITERATUR

Anggit Ferdita Nugraha ¹⁾, Yoga Pristyanto ²⁾, Irfan Pratama ³⁾

¹⁾ Teknik Komputer Universitas AMIKOM Yogyakarta

²⁾ Sistem Informasi Universitas AMIKOM Yogyakarta

³⁾ Sistem Informasi Universitas Mercubuana Yogyakarta

email : anggitferdita@amikom.ac.id ¹⁾, yoga.pristyanto@amikom.ac.id ²⁾, irfanp@mercubuana-yogya.ac.id ³⁾

Abstraksi

Pendidikan berperan penting dalam meningkatkan kualitas hidup masyarakat di suatu negara. Pendidikan terbagi menjadi dua yaitu formal dan informal. Mayoritas pendidikan formal diselenggarakan melalui kelas konvensional. Dalam kelas konvensional, jumlah siswa yang banyak dapat menyebabkan materi tidak dapat tersampaikan dengan baik. Oleh karena itu diperlukan pemahaman para pengajar untuk mengetahui kinerja yang dimiliki masing-masing siswa. Teknik klasifikasi dapat digunakan untuk menyelesaikan permasalahan tersebut. Paper ini akan membahas atribut dan algoritma yang dapat digunakan dalam klasifikasi siswa. Pada klasifikasi siswa perlu memperhatikan beberapa atribut diantaranya Indeks Prestasi dan Indeks Prestasi Kumulatif. Beberapa algoritma yang dapat digunakan untuk mengklasifikasikan siswa yaitu C4.5, J48, Naive Bayes, ANN, Esemble (Neural Network dan k-Nearest Neighbor). Untuk penelitian selanjutnya dapat ditambahkan aspek kognitif, psikomotorik dan afektif sebagai atribut. Sedangkan algoritma Support Vector Machine dan beberapa kombinasi algoritma dapat diujikan.

Kata Kunci :

Educational Data Mining, Classification, Students Classification, Students Performance.

Abstract

Education plays an important role in improving the quality of life of people in a country. Education is divided into two namely formal and informal. The majority of formal education is organized through conventional classes. In conventional classrooms, the large number of students can cause material not to be conveyed properly. Therefore, it requires the understanding of teachers to know the performance of each student. Classification techniques can be used to solve these problems. This paper will discuss the attributes and algorithms that can be used in classifying students. In the classification of students need to pay attention to several attributes including the Achievement Index and the Cumulative Achievement Index. Some algorithms that can be used to classify students are C4.5, J48, Naive Bayes, ANN, Esemble (Neural Network and k-Nearest Neighbor). For further research cognitive, psychomotor and affective aspects can be added as attributes. While the Support Vector Machine algorithm and several combinations of algorithms can be tested..

Keywords :

Educational Data Mining, Classification, Students Classification, Students Performance.

Pendahuluan

Pendidikan merupakan salah satu faktor penting pada setiap negara untuk meningkatkan kualitas hidup masyarakat. Di beberapa negara, pemerintah berperan penting pada peningkatan sistem pendidikan [1]. Di Indonesia, terdapat tiga satuan proses penyelenggaraan pendidikan yaitu formal, non formal, dan informal yang telah diatur didalam Undang-Undang [2]. Pendidikan formal diselenggarakan melalui kelas konvensional di sekolah. Permasalahan yang terjadi pada kelas konvensional ialah jumlah siswa yang sangat banyak, sehingga materi pembelajaran tidak dapat tersampaikan dengan baik. Dikarenakan setiap siswa memiliki metode belajar masing-masing [3]. Jika para pengajar memahami metode belajar yang dimiliki oleh siswa dan tingkat pengetahuan siswa mengenai materi, para pengajar dapat mempersiapkan materi pembelajaran yang tepat untuk masing-masing siswa. Hal ini dapat meningkatkan kemampuan serta menjadikan proses pembelajaran lebih efisien [1]. Sehingga diperlukan pengelompokan siswa berdasarkan metode belajarnya untuk memprediksi kinerjanya di kelas [3].

Salah satu metode yang dapat digunakan dalam pengelompokan siswa ialah data mining. Data mining merupakan sebuah konsep untuk mengenali pola yang tersembunyi dan menemukan relasi antar parameter di dalam jumlah data yang besar [4]. Data mining banyak digunakan dalam berbagai bidang seperti medis, teknik, ekonomi, keuangan, dan pendidikan. Hal ini menunjukkan data mining dapat memberikan solusi alternatif bagi para pengambil keputusan dalam memecahkan suatu masalah tertentu. Eksplorasi data yang dilakukan pada bidang pendidikan sering dikenal dengan istilah Educational Data Mining (EDM) [5]. EDM merupakan proses yang digunakan untuk mengekstrak informasi yang berguna dan mengenali pola dari database pendidikan yang jumlahnya besar [6].

Di dalam data mining terdapat beberapa metode yang digunakan, salah satunya ialah metode klasifikasi. Klasifikasi merupakan sebuah proses menemukan sebuah model atau pola yang menggambarkan dan membedakan kelas pada suatu dataset, agar dapat menggunakan model untuk memprediksi obyek dengan label kelas yang tidak diketahui. Model tersebut didasarkan pada analisis data latih. Model dari hasil klasifikasi dapat dimanfaatkan untuk memprediksi tren data masa depan [7]. Sebelum dilakukan proses klasifikasi hendaknya didahului dengan analisis dan identifikasi atribut penting dan atribut tidak penting yang akan digunakan dalam proses klasifikasi [3].

Pada review paper ini akan fokus membahas dua hal yaitu :

1. Indikator apa saja yang dapat dijadikan atribut atau variabel untuk mengelompokkan siswa berdasarkan kemampuan dan tingkat keberhasilannya.
2. Algoritma klasifikasi apa saja yang dapat digunakan untuk mengelompokkan dataset siswa.

Dataset Siswa

Dataset siswa memiliki banyak sekali atribut. Oleh karena itu diperlukan identifikasi indikator yang memiliki faktor penting untuk dijadikan sebagai atribut dalam pengelompokan siswa. Beberapa penelitian yang dilakukan sebelumnya menyebutkan bahwa atribut penting yang digunakan untuk pengelompokan siswa ialah Indeks Prestasi dan Indeks Prestasi Kumulatif.

Chusak et al. [8] melakukan pengelompokan mahasiswa berdasarkan perilaku di kelas. Dalam penelitian tersebut dataset yang digunakan yaitu data akademik mahasiswa berupa data perilaku dalam belajar dan data akademik mahasiswa (Indeks Prestasi dan Nilai dari 4 mata kuliah) dari masing-masing mahasiswa.

Oktariani [9] melakukan pengelompokan siswa untuk memprediksi kelas jurusan yang tepat bagi siswa sekolah menengah atas. Dalam penelitian tersebut digunakan dataset akademik siswa berupa nilai akademik selama 2 semester yang meliputi nilai dari 16 mata pelajaran.

Indriana et al. [3] dalam penelitiannya melakukan pengelompokan mahasiswa untuk mengetahui tingkat kemampuannya. Dataset yang digunakan merupakan kuisioner yang berkaitan dengan aspek psikologi mahasiswa dengan parameter berupa *intelligence, interests, talents*, dan *motivations*.

Fadhilah et al. [5] melakukan pengelompokan mahasiswa untuk membantu meningkatkan kinerja siswa. Dalam penelitiannya menggunakan dataset berupa profil dan akademik dari mahasiswa. Atribut utama yang digunakan untuk pengelompokan ialah Indeks Prestasi.

Tripti et al. [10] melakukan pengelompokan mahasiswa untuk memprediksi kinerja mahasiswa selama semester 3. Dalam penelitiannya menggunakan data akademik dengan atribut berupa nilai pada saat Sekolah Menengah Atas, Indeks Prestasi semester 1, dan Indeks Prestasi semester 2.

Mayilvaganan et al. [11] dalam penelitiannya melakukan pengelompokan mahasiswa untuk mengetahui dan membantu mahasiswa yang lemah dalam belajar. Dataset yang digunakan merupakan data akademik mahasiswa dengan atribut berupa Indeks Prestasi, nilai ujian dan nilai praktikum dari mahasiswa.

Tjioe et al. [7] dalam penelitiannya menggunakan dua jenis dataset mahasiswa yang digunakan, yang pertama yaitu dataset mahasiswa yang masih aktif berupa profil, latar pendidikan sebelumnya, data admisi, dan data akademik. Dataset yang kedua yaitu data mahasiswa yang telah lulus berupa profil, latar pendidikan sebelumnya, dan data akademik. Pada dataset pertama hasil pengelompokan akan digunakan untuk memprediksi tingkat keberhasilan mahasiswa selama perkuliahan. Sedangkan pada dataset kedua akan digunakan untuk memprediksi hasil belajar dan waktu belajar. Dari kedua dataset tersebut atribut yang memiliki peran dalam pengelompokan mahasiswa ialah data akademik berupa nilai ujian dan Indeks Prestasi

Karan et al. [12] melakukan pengelompokan mahasiswa untuk mengetahui tingkat kemampuannya di dalam perkuliahan. Dalam penelitiannya menggunakan data akademik mahasiswa yang berupa Indeks Prestasi Kumulatif dan nilai dari 25 matakuliah.

Norlida et al. [13] dalam penelitiannya menggunakan data akademik mahasiswa yang berupa Indeks Prestasi Kumulatif untuk mengetahui dan memprediksi tingkat keberhasilan siswa dalam pembelajaran.

Parneet et al. [4] melakukan pengelompokan siswa untuk memprediksi tingkat keberhasilannya selama belajar di sekolah. Berdasarkan dataset tersebut atribut yang memiliki peran dalam pengelompokan siswa ialah berupa nilai mata pelajaran dan jumlah kehadiran.

Worapat et al. [1] dalam penelitiannya data yang digunakan ada 2 jenis yaitu data profil mahasiswa dan Felder-Silverman Questionnaire. Untuk profil mahasiswa meliputi informasi akademik. Sedangkan Felder Silverman Questionnaire merupakan sebuah kuisioner yang berhubungan dengan *learning style*, berdasarkan kuisioner tersebut *learning style* dikategorikan menjadi 4 kelompok yaitu *Active-Reflective*, *Sensing-Intuitive*, *Visual-Verbal*, dan *Sequential-Global*.

Metode Klasifikasi

Di dalam metode klasifikasi terdapat banyak algoritma populer yang dapat digunakan untuk membantu menyelesaikan masalah pada bidang Educational Data Mining (EDM).

Chusak et al. [8] metode yang diusulkan dalam penelitian ini menggunakan klastering dan klasifikasi. Tahap pertama metode klastering digunakan untuk mengelompokkan mahasiswa berdasarkan perilaku dalam belajar, dengan menggunakan algoritma *K-Means* mahasiswa dikelompokkan ke dalam 4 klaster. Kemudian hasil dari proses klaster tersebut dijadikan atribut tambahan dalam proses klasifikasi. Dengan menggunakan hasil klaster dan data akademik (Indeks Prestasi dan Nilai dari 4 mata kuliah), pada tahap klasifikasi ini mahasiswa dikategorikan menjadi 4 yaitu *excellent*, *good*, *medium* and *weak* dengan menggunakan algoritma *Decision Tree C4.5*. Dengan menggunakan *10-fold cross validation*, pada penelitian tersebut menghasilkan nilai presisi 83.8%, *recall* 85.4%, dan F-measure 85.5%. Algoritma *Decision Tree C4.5* yang digunakan dalam klasifikasi pada penelitian ini menghasilkan klasifikasi cukup akurat dalam menangani *multiclass* klasifikasi.

Oktariani [9] menggunakan metode klasifikasi untuk mengkategorikan siswa ke dalam dua kelas yaitu IPA maupun IPS. Dalam penelitian tersebut diusulkan perbandingan 6 algoritma klasifikasi untuk mendapatkan tingkat akurasi yang paling tinggi. Algoritma yang digunakan ialah J48, SimpleCart, Kstar, SMO (*Sequential Minimal Optimization*), Naïve Bayes, OneR. Dalam tahap klasifikasi terdapat dua skenario, pertama proses klasifikasi dengan atribut berupa nilai 16 mata pelajaran. Kedua proses

klasifikasi dengan atribut berupa nilai 13 mata pelajaran. Dengan menggunakan *10-fold cross validation*, pada skenario yang pertama nilai akurasi dari keenam algoritma ialah J48 79.61%, SimpleCart 78.34%, Kstar 69.74%, SMO 77.38%, Naïve Bayes 76.75%, OneR 78.66%. Sedangkan pada skenario yang kedua nilai akurasi dari keenam algoritma ialah J48 79.61%, SimpleCart 79.61%, Kstar 74.52%, SMO 75.15%, Naïve Bayes 78.34%, OneR 78.66%. Dari keenam algoritma klasifikasi yang digunakan, J48 menghasilkan akurasi dan konsistensi yang paling baik dengan dua kali skenario pengujian. Selain itu algoritma J48 cukup baik dan akurat dalam klasifikasi dua kelas.

Tripti et al. [10] metode yang diusulkan dalam penelitian ini menggunakan klasifikasi untuk memprediksi kinerja mahasiswa selama semester 3. Mahasiswa dikategorikan kedalam 4 kelompok yaitu *excellent*, *above average*, *average*, *below average*. Atribut yang digunakan berupa nilai pada saat Sekolah Menengah Atas, Indeks Prestasi semester, dan Indeks Prestasi semester 2. Dalam penelitian tersebut digunakan perbandingan dua algoritma *Decision Tree* J48 dan *Random Tree*. Dengan menggunakan *cross validation* nilai akurasi J48 88.3721%, dan *Random Tree* 94.4186%. Algoritma *Random Tree* memiliki nilai akurasi yang lebih baik dibandingkan J48. Baik J48 dan *Random Tree* memiliki akurasi yang baik dalam menangani *multiclass* klasifikasi.

Karan et al. [12] dalam penelitiannya menggunakan metode klasifikasi untuk mengkategorikan mahasiswa ke dalam dua kelas yaitu lulus dan tidak lulus. Algoritma yang digunakan yaitu C4.5 dan Naïve Bayes. Atribut yang digunakan berupa Indeks Prestasi Kumulatif dan nilai dari 25 matakuliah. Pada penelitian tersebut menghasilkan nilai akurasi dari kedua algoritma sebesar 82.39% pada C4.5 dan 62.1% pada Naïve Bayes. Algoritma C4.5 yang digunakan dalam klasifikasi pada penelitian ini menghasilkan klasifikasi cukup akurat dalam menangani klasifikasi dua kelas dibandingkan algoritma Naïve Bayes.

Parneet et al. [4] menggunakan metode klasifikasi untuk mengkategorikan siswa ke dalam dua kelas yaitu lulus maupun tidak lulus. Metode diusulkan ialah perbandingan 5 algoritma klasifikasi yaitu untuk mendapatkan tingkat akurasi yang paling tinggi. Algoritma yang digunakan yaitu *Multilayer Perceptron*, Naïve Bayes, SMO (*Sequential Minimal Optimization*), J48, dan REPTree. Dengan menggunakan *cross validation*, pada penelitian tersebut menghasilkan nilai akurasi dari kelima algoritma sebesar *Multilayer Perceptron* 75%, Naïve Bayes 65.13%, SMO (*Sequential Minimal Optimization*) 68.42%, J48 69.73%, dan REPTree 67.76%. Dari kelima algoritma klasifikasi yang digunakan, *Multilayer Perceptron* menghasilkan akurasi paling baik dibandingkan algoritma yang lain. Selain itu algoritma *Multilayer Perceptron* juga cukup baik dan akurat dalam menangani klasifikasi dua kelas.

Waropat et al. [1] mengusulkan metode klasifikasi dengan algoritma ensemble hasil kombinasi dari *Neural Network* dan

k-Nearest Neighbor. Algoritma esemble tersebut akan dibandingkan dengan 4 algoritma klasifikasi lainnya yaitu Decision Tree, Naïve Bayes, Artificial Neural Network, dan Support Vector Machine. Dalam penelitian tersebut mahasiswa dikategorikan menjadi 4 kelas sesuai *learning style* nya yaitu *Active-Reflective*, *Sensing-Intuitive*, *Visual-Verbal*, dan *Sequential-Global*. Dengan menggunakan *10-fold cross validation*, nilai akurasi dari kelima algoritma ialah Decision Tree 62.77%, Naïve Bayes 42.55%, Artificial Neural Network 88.30%, Support Vector Machine 25.53%, dan Esemble 90.43%. Dari kelima algoritma klasifikasi yang

digunakan, algoritma esemble menghasilkan akurasi yang paling baik dibandingkan algoritma yang lain. Selain algoritma esemble, algoritma Artificial Neural Network juga akurat dalam menangani *multiclass* klasifikasi.

Pembahasan

Pada tahap ini pembahasan akan difokuskan pada 2 hal yaitu mengenai indikator yang dapat dijadikan atribut atau variabel untuk mengelompokkan siswa berdasarkan kemampuan dan tingkat keberhasilannya, serta algoritma klasifikasi yang dapat digunakan untuk mengelompokkan dataset siswa.

TABEL 1 PERBANDINGAN METODE

Klasifikasi Dua Kelas					
Peneliti	Tahun	Atribut	Metode	Akurasi	
Oktariani [9]	2013	<ul style="list-style-type: none"> - Nilai 16 mata pelajaran (pengujian pertama) - Nilai 13 mata pelajaran (pengujian kedua) 	J48	Pengujian 1	Pengujian 2
			SimpleCart	79.61%	79.61%
			Kstar	78.34%	79.61%
			SMO (Sequential Minimum Optimization)	69.74%	74.52%
			Naïve Bayes	77.38%	75.15%
			OneR	76.75%	78.34%
Tjioe et al. [7]	2014	- Indeks Prestasi	NBTree	-	-
Karan et al. [12]	2015	<ul style="list-style-type: none"> - Indeks Prestasi Kumulatif - Nilai dari 25 mata kuliah 	Decision Tree C4.5	82.39%	
			Naïve Bayes	62.1%	
Parneet et al. [4]	2015	<ul style="list-style-type: none"> - Nilai mata pelajaran - Jumlah kehadiran 	Multilayer Perception	75%	
			Naïve Bayes	65.13%	
			SMO (Sequential Minimum Optimization)	68.42%	
			J48	69.73%	
			Reduced Error Pruning Decision Tree	67.76%	
Chusak et al. [8]	2013	<ul style="list-style-type: none"> - Indeks Prestasi - Nilai dari 4 mata kuliah 	Decision Tree C4.5	83.5%	
Indriana et al. [3]	2013	- Faktor psikologi yang meliputi intelligence, interests, talents, dan motivations.	Neuro-Fuzzy	Root Mean Square Error : 0.25611	
Mayilvaganan et al. [11]	2014	<ul style="list-style-type: none"> - Indeks Prestasi - Nilai Ujian - Nilai Praktikum 	C4.5	-	
			Naïve Bayes		
			Aggregating One-Dependence Estimators Multi-labeled K-Nearest Neighbor		
Fadhilah et al. [5]	2014	- Indeks Prestasi	Decision Tree J48	68.8%	
			Naïve Bayes	67%	
			Rule Based	71.3 %	
Tripti et al. [10]	2014	<ul style="list-style-type: none"> - Nilai saat SMA - Indeks Prestasi semester 1 - Indeks Prestasi semester 2 	J48	94.4186%	
			Random Tree	88.3721%	
Norlida et al. [13]	2015	- Indeks Prestasi Kumulatif	Neuro-Fuzzy	-	
Worapat et al. [1]	2015	<ul style="list-style-type: none"> - Learning style yang meliputi Active-Reflective, Sensing-Intuitive, Visual-Verbal, dan Sequential-Global 	Decision Tree	62.77%	
			Naïve Bayes	42.55%	
			Artificial Neural Network	88.30%	
			Support Vector Machine	25.53%	
			Neural Network + k-Nearest Neighbor	90.43%	

Tabel 1 menjelaskan metode yang digunakan untuk klasifikasi dua kelas dan multikelas. Selain itu pada tabel tersebut dijelaskan mengenai atribut yang digunakan serta hasil perbandingan dari semua metode yang dilakukan. Tetapi tidak semua peneliti menjelaskan hasil secara kuantitatif.

Berdasarkan beberapa penelitian diatas, terdapat berbagai macam indikator yang dapat dijadikan atribut untuk memprediksi kinerja dan prestasi siswa. Atribut yang sering digunakan ialah Indeks Prestasi [5], [7], [8], [10], [11] dan Indeks Prestasi Kumulatif [12] [13]. Ada pula penelitian yang menggunakan atribut internal tes yang meliputi nilai mata kuliah [8], [12] atau mata pelajaran [4], [9], nilai praktikum [11], nilai ujian [7], [11], kehadiran [4]. Selain itu ada penelitian yang menggunakan aspek psikologi yang meliputi motivasi, bakat, kecerdasan, minat [3], dan learning style [1].

Tabel diatas juga menunjukkan beberapa algoritma yang digunakan dalam klasifikasi, baik klasifikasi dua kelas maupun multikelas. Dari beberapa algoritma yang dijelaskan pada Tabel 1, beberapa diantaranya memiliki kinerja hasil yang cukup baik dengan tingkat akurasi diatas 75% dan sering digunakan dalam teknik klasifikasi.

Dalam klasifikasi dua kelas, Oktariani [9] memperoleh tingkat akurasi sebesar 79.61% pada J48, 78.34% pada SimpleCart, 77.38% pada SMO (Sequential Minimum Optimization), 76.75% pada Naïve Bayes, 78.66% pada OneR didalam pengujian pertama. Pada pengujian kedua diperoleh J48 79.61%, SimpleCart 79.61%, SMO (Sequential Minimum Optimization) 75.15%, Naive Bayes 78.34%, OneR 78.66% pada pengujian kedua. Karan et al. [12] memperoleh tingkat akurasi sebesar 82.39% pada algoritma C4.5, sedangkan Parneet et al. [4] dalam penelitiannya memperoleh tingkat akurasi sebesar 75% pada penggunaan algoritma MLP (Multilayer Perceptron).

Dalam klasifikasi multikelas, Chusak et al. [8] memperoleh tingkat akurasi sebesar 83.5% pada algoritma C4.5. Tripti et al. [10] dalam penelitiannya memperoleh tingkat akurasi sebesar 94.4186% pada algoritma J48 dan 88.3721% pada penggunaan Random Tree. Sedangkan Worapat et al. dalam penelitiannya memperoleh tingkat akurasi sebesar 88.30% pada algoritma Artificial Neural Network dan 90.43% pada penggunaan algoritma ensemble (kombinasi antara Neural Network dan k-Nearest Neighbor).

Kesimpulan dan Saran

Berdasarkan penjelasan dari beberapa penelitian yang telah dilakukan, dapat disimpulkan bahwa dalam Educational Data Mining (EDM) atribut yang paling sering digunakan untuk memprediksi kinerja siswa selama belajar ialah Indeks Prestasi dan Indeks Prestasi Kumulatif. Indeks Prestasi

maupun Indeks Prestasi Kumulatif merupakan sebuah indikator yang mampu menunjukkan kinerja dan potensi mahasiswa selama belajar. Selain itu Indeks Prestasi maupun Indeks Prestasi Kumulatif juga dapat menentukan apakah mahasiswa dapat menyelesaikan studinya dengan baik atau tidak. Meskipun aspek psikologi siswa yang meliputi motivasi, bakat, kecerdasan, minat, serta learning style dapat juga digunakan menjadi atribut.

Selain itu beberapa algoritma cukup efektif dan dapat digunakan dalam Educational Data Mining (EDM). Dalam klasifikasi dua kelas dapat menggunakan algoritma Decision Tree C4.5, J48 dan Naïve Bayes. Sedangkan dalam klasifikasi multikelas dapat menggunakan algoritma Decision Tree J48, Artificial Neural Network, serta kombinasi antara algoritma Neural Network dan k-Nearest Neighbor.

Untuk penelitian yang akan datang, beberapa aspek dapat digunakan sebagai atribut seperti aspek kognitif, aspek afektif, dan aspek psikomotorik dari siswa tersebut. Selain itu beberapa algoritma seperti Support Vector Machine dan beberapa kombinasi algoritma juga dapat diuji cobakan.

Daftar Pustaka

- [1] W. Paireekreng and T. Prexawanprasut, "An integrated model for learning style classification in university students using data mining techniques," *2015 12th Int. Conf. Electr. Eng. Comput. Telecommun. Inf. Technol.*, pp. 1–5, 2015.
- [2] Presiden RI, "Undang-Undang Republik Indonesia Nomor 20 Tahun 2003 Tentang Sistem Pendidikan Nasional," *Tambah. Lembaran Negara Republik Indones. Nomor 4301*, no. 1, pp. 1–26, 2003.
- [3] I. Hidayah, A. E. Permanasari, and N. Ratwastuti, "Student classification for academic performance prediction using neuro fuzzy in a conventional classroom," *Inf. Technol. Electr. Eng. (ICITEE), 2013 Int. Conf.*, pp. 221–225, 2013.
- [4] P. Kaur, M. Singh, and G. Singh, "Classification and prediction based data mining algorithms to predict slow learners in education sector," *Procedia - Procedia Comput. Sci.*, vol. 57, pp. 500–508, 2015.
- [5] F. Ahmad, N. H. Ismail, and A. A. Aziz, "The Prediction of Students' Academic Performance Using Classification Data Mining Techniques," *World Appl. Sci. J.*, vol. 9, no. 129, pp. 6415–6426, 2014.
- [6] C. Bambrah, M. Bhandari, N. Maniar, and V. Munde, "Mining Association Rules in Student Assessment Data," *Int. J. Adv. Res. Comput. Commun. Eng.*, vol. 3, no. 3, pp. 5340–5342, 2014.
- [7] T. M. Christian and M. Ayub, "Exploration of classification using NBTree for predicting students' performance," *Proc. 2014 Int. Conf. Data Softw. Eng. ICODSE 2014*, pp. 0–5, 2014.
- [8] C. Yathongchai, T. Angskun, W. Yathongchai, and J. Angskun, "Learner classification based on learning

- behavior and performance,” *2013 IEEE Conf. Open Syst.*, pp. 66–70, 2013.
- [9] O. N. Pratiwi, “Predicting student placement class using data mining,” *Proc. 2013 IEEE Int. Conf. Teaching, Assess. Learn. Eng. TALE 2013*, no. August, pp. 618–621, 2013.
- [10] T. Mishra, D. Kumar, and S. Gupta, “Mining students’ data for prediction performance,” *Int. Conf. Adv. Comput. Commun. Technol. ACCT*, pp. 255–262, 2014.
- [11] M. Mayilvaganan and D. Kalpanadevi, “Comparison of classification techniques for predicting the performance of students academic environment,” *Commun. Netw. Technol. (ICCNT), 2014 Int. Conf.*, pp. 113–118, 2014.
- [12] K. Pruthi and P. Bhatia, “Application of Data Mining in predicting placement of students,” *2015 Int. Conf. Green Comput. Internet Things*, pp. 528–533, 2015.
- [13] N. Buniyamin, U. Mat, and P. M. Arshad, “Educational Data Mining for Prediction and Classification of Engineering Students Achievement,” *IEEE 7th Int. Conf. Eng. Educ.*, pp. 49–53, 2015.
- [14] U. Bin Mat, N. Buniyamin, P. M. Arsad, and R. A. Kassim, “An overview of using academic analytics to predict and improve students’ achievement: A proposed proactive intelligent intervention,” *2013 IEEE 5th Int. Conf. Eng. Educ. Aligning Eng. Educ. with Ind. Needs Nation Dev. ICEED 2013*, pp. 126–130, 2014.