

Klasifikasi kebutuhan fungsional dan non fungsional dalam pengembangan perangkat lunak e-learning

Nenden Nuraeni

Program Studi Teknik Informatika, Universitas Islam Negeri Maulana Malik Ibrahim Malang
e-mail: 210605110149@student.uin-malang.ac.id

Kata Kunci:

klasifikasi; e-learning; naïve bayes; rapidminer; user reuirement

Keywords:

classification; e-learning; naïve bayes; rapidminer; user reuirement

ABSTRAK

Dalam bidang pendidikan, teknologi telah menjadi bagian integral dari kehidupan manusia. Pemanfaatan teknologi dalam bentuk platform e-learning memungkinkan akses pembelajaran secara fleksibel dan online. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan platform e-learning yang lebih baik sesuai dengan kebutuhan pengguna di bidang pendidikan. Fokus penelitian ini adalah bagaimana memfasilitasi pengembang dalam proses desain perangkat lunak dengan menggunakan Persyaratan Pengguna dan memberikan analisis sebagai dasar pengembangan perangkat lunak e-learning. Metode yang

digunakan adalah Naive Bayes dengan menggunakan alat analisis data Rapidminer. Klasifikasi persyaratan pengguna melibatkan identifikasi, pengelompokan, dan evaluasi persyaratan fungsional dan non-fungsional. Hasil evaluasi menunjukkan bahwa model yang dibangun berperforma baik, didukung oleh akurasi sebesar 88.89% dan presisi yang tinggi. Model ini mampu melakukan prediksi dengan akurasi yang baik dan memiliki presisi yang tinggi dalam memprediksi kelas non-fungsional. Dalam penelitian ini, terdapat 50 data yang terdiri dari data fungsional dan nonfungsional. Data tersebut dibagi menjadi dua subset: 28% untuk data pelatihan dan 72% untuk data pengujian. Pembagian ini penting untuk memastikan representasi yang adil dalam analisis dan pengujian model. Hal ini membantu mendapatkan gambaran yang lebih akurat tentang kemampuan dan kehandalan model dalam mengklasifikasikan data fungsional dan nonfungsional.

ABSTRACT

In education, technology has become an integral part of human life. Utilizing technology in the form of e-learning platforms allows access to learning flexibly and online. Therefore, this research aims to develop a better e-learning platform for the needs of users in the field of education. The focus of this research is how to facilitate developers in the software design process by using User Requirements and providing analysis as the basis for e-learning software development. The method used is Naive Bayes by using the Rapidminer data analysis tool. Classification of user requirements involves identifying, grouping, and evaluating functional and non-functional requirements. The evaluation results show that the built model performs well, supported by 88.89% accuracy and high precision. The model can predict with good accuracy and has high precision in predicting non-functional classes. In this study, 50 data sets consist of functional and nonfunctional data. The data is divided into two subsets: 28% for training data and 72% for testing data. This division is important to ensure fair representation in model analysis and testing. This helps to get a more accurate picture of the model's ability and reliability in classifying functional and nonfunctional data.

Pendahuluan

Pada zaman sekarang, teknologi telah menjadi bagian yang tidak terpisahkan dari kehidupan manusia. Pemanfaatan teknologi dalam berbagai aspek kehidupan semakin meningkat, termasuk dalam bidang Pendidikan (Sani et al., 2024). Salah satu bentuk



This is an open access article under the [CC BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/) license.

Copyright © 2023 by Author. Published by Universitas Islam Negeri Maulana Malik Ibrahim Malang.

pemanfaatan teknologi dalam bidang pendidikan adalah dengan menggunakan platform e- learning untuk menunjang proses belajar dan mengajar (Zulpukarova et al., 2024).

Platform e-learning merupakan sebuah sistem pembelajaran yang memanfaatkan teknologi internet sebagai media utama dalam proses belajar-mengajar. Melalui platform e-learning, pengguna dapat mengakses materi pembelajaran secara online dan fleksibel tanpa harus hadir di kelas fisik. Platform e-learning merupakan sebuah inovasi yang digunakan untuk meningkatkan kualitas pembelajaran dengan memberikan akses mudah dan efisien ke materi pembelajaran bagi pengguna (Serwornoo et al., 2024). Dalam pengembangan platform e-learning, penting untuk memperhatikan kebutuhan pengguna dan melakukan klasifikasi kebutuhan pengguna dengan baik (Wienand et al., 2024). Klasifikasi kebutuhan pengguna melibatkan identifikasi, pengelompokan, dan penilaian kebutuhan pengguna berdasarkan kategori tertentu seperti kebutuhan fungsional dan non- fungsional. Dengan mengklasifikasikan kebutuhan pengguna dengan baik, platform e-learning dapat dikembangkan menjadi lebih efektif dan berkualitas.

Dalam pengembangan platform e- learning, salah satu hal yang penting adalah memperhatikan kebutuhan pengguna (Kong et al., 2024). Oleh karena itu, di dalam Paper ini membahas masalah bagaimana cara memudahkan developer dalam proses perancangan perangkat lunak dengan menggunakan User Requirement dan bagaimana cara menyediakan analisisnya sebagai dasar dalam perancangan pengembangan perangkat lunak e-learning. Dalam proses klasifikasi kebutuhan pengguna ini melibatkan identifikasi, pengelompokan, dan penilaian kebutuhan pengguna berdasarkan kategori tertentu, seperti kebutuhan fungsional, non-fungsional (Budake et al., 2024). Dengan mengklasifikasikan kebutuhan pengguna dengan baik, diharapkan platform e- learning dapat dikembangkan menjadi lebih berkualitas dan efektif.

Dalam penelitian ini, penulis menggunakan metode Naive Bayes dengan menggunakan tools Rapidminer sebagai alat analisis data. Metode Naive Bayes merupakan salah satu metode klasifikasi pada data mining yang dapat digunakan untuk memprediksi kelas atau kategori dari suatu data berdasarkan beberapa variabel atau atribut yang ada pada data tersebut (Zahri et al., 2024). Tools Rapidminer sendiri adalah sebuah platform open- source untuk data mining yang dapat digunakan untuk melakukan berbagai macam analisis data (Senan & Tasci, 2024).

Dengan melakukan penelitian mengenai klasifikasi kebutuhan pengguna pada platform e-learning diharapkan dapat memberikan manfaat bagi pengguna dalam memperoleh akses pembelajaran yang lebih baik. Selain itu, penelitian ini juga dapat memberikan manfaat bagi khalayak umum dalam mengembangkan platform e-learning yang lebih berkualitas dan efektif.

Pembahasan

Untuk mengklasifikasikan data kebutuhan pengguna dalam e-learning, penulis mengumpulkan informasi yang diperlukan melalui interaksi dengan Chat GPT. Proses ini melibatkan mengajukan pertanyaan kepada Chat GPT dan mendapatkan tanggapan

yang berkaitan dengan kebutuhan pengguna dalam konteks e-learning. Data yang dikumpulkan kemudian diklasifikasikan berdasarkan kategori atau jenis kebutuhan yang diungkapkan oleh pengguna. Dengan demikian, penulis dapat mengidentifikasi dan memahami berbagai aspek kebutuhan pengguna terkait e-learning, seperti fitur, konten, antarmuka pengguna, atau dukungan teknis. Data ini dapat digunakan untuk menganalisis tren, mengembangkan solusi yang lebih baik, atau menyusun strategi pengembangan yang lebih efektif dalam bidang e-learning.

Setelah data terkumpul, penulis akan melakukan klasifikasi data dengan mengidentifikasi, mengelompokkan, dan menilai kebutuhan pengguna berdasarkan kategori tertentu, seperti kebutuhan fungsional, non-fungsional. Untuk melakukan klasifikasi user requirements dengan studi kasus e-learning menggunakan Naive Bayes di RapidMiner, terdapat prosedur langkah - langkah berikut ini :

1. Persiapan Data

- a. Identifikasi data yang akan digunakan dan pastikan data sudah bersih dan terstruktur.
- b. Siapkan dataset dengan mengumpulkan data requirement dari pengguna e-learning.
- c. Lakukan pra-pemrosesan data untuk membersihkan data dari noise dan menghasilkan data yang siap digunakan dalam proses analisis.

2. Pemodelan


- a. Buat sebuah project baru di RapidMiner.
- b. Impor dataset yang sudah diproses dari tahap pra- pemrosesan.
- c. Buat sebuah proses aliran kerja (workflow) di RapidMiner dengan menggunakan operator-operator yang diperlukan untuk membangun model Naive Bayes.
- d. Gunakan operator "Process Documents" untuk mengubah dokumen teks menjadi representasi numerik.
- e. Gunakan operator "Filter Stopwords" untuk menghilangkan kata-kata yang umum dan tidak informatif.
- f. Buat model klasifikasi Naive Bayes dengan menggunakan operator "Naive Bayes" pada RapidMiner. Sesuaikan parameter model sesuai dengan kebutuhan analisis.
- g. Evaluasi kinerja model dengan menggunakan operator "Performance" untuk memperoleh informasi tentang sakurasi, presisi, dan recall dari model. Jika hasilnya tidak memuaskan, maka Anda dapat memperbaiki model dengan mengubah parameter atau memperbarui data yang digunakan.

3. Implementasi Model


- a. Gunakan model yang telah dibuat untuk mengklasifikasikan data baru.
- b. Gunakan operator "Apply Model" untuk menghasilkan prediksi label dari data baru.

- c. Berikan rekomendasi tentang apakah permintaan pengguna dapat dipenuhi atau tidak.
4. Pengujian
 - a. Lakukan pengujian dengan menggunakan data yang berbeda untuk menguji kinerja model
 - b. Analisis hasil pengujian dan perbaiki model jika diperlukan.
5. Implementasi
 - a. Implementasikan model yang telah dibuat ke dalam sistem e- learning.
 - b. Gunakan model untuk memproses permintaan pengguna dan memberikan rekomendasi tentang apakah permintaan tersebut dapat dipenuhi atau tidak.
6. Evaluasi
 - a. Evaluasi hasil implementasi model untuk memastikan apakah model yang dibuat efektif dan efisien dalam memproses permintaan pengguna.
 - b. Perbaiki model jika diperlukan.

Berikut adalah diagram alur penggunaan algoritma naïve bayes di Rapidminer dan gambar tahapan metode penelitian yang dilakukan:



Gambar 1. Flowchart Rapidminer.



Gambar 2. Alur Penelitian.

Naïve Bayes

Metode Naive Bayes merupakan salah satu metode klasifikasi yang paling umum digunakan untuk memproses data teks (Kumar et al., 2024). Metode ini dapat digunakan untuk memprediksi label atau kelas yang paling mungkin diberikan fitur yang diberikan dalam suatu dokumen atau data teks (Diantoro & Santoso, 2017; Veziroğlu et al., 2024). Metode ini memanfaatkan teori probabilitas dan asumsi Naive Bayes yang menyatakan bahwa setiap fitur dalam dokumen adalah independen satu sama lain (Li, 2024; Santoso et al., n.d.). Oleh karena itu, metode ini sangat cocok untuk mengklasifikasikan data teks dengan jumlah fitur yang besar.

Naive Bayes memiliki kemampuan untuk mengatasi masalah dimensi yang tinggi dan mampu menghasilkan hasil klasifikasi yang akurat dengan waktu komputasi yang cepat (Kumar et al., 2024). Oleh karena itu, metode ini menjadi pilihan yang sangat baik untuk aplikasi analisis teks yang memerlukan klasifikasi data dalam waktu yang cepat dan akurat.

Naive Bayes adalah sebuah metode yang dapat memprediksi probabilitas suatu kelas. Metode ini didasarkan pada teori Bayesian. Naive Bayes memiliki asumsi bahwa nilai atribut kelas tidak tergantung pada nilai atribut lainnya.

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)}$$

Di mana C_i adalah nilai terbesar dari sebuah data, $P(X)$ adalah konstanta untuk semua class, dan P adalah Posterior propability.

Dataset

Dalam penelitian ini, terdapat 50 data yang terdiri dari data fungsional dan nonfungsional. Data tersebut dibagi menjadi dua subset: 28% untuk data pelatihan dan 72% untuk data pengujian. Pembagian ini penting untuk memastikan representasi yang adil dalam analisis dan pengujian model. Data pelatihan digunakan untuk melatih model, sedangkan data pengujian digunakan untuk menguji kinerja model yang telah dilatih. Hal ini membantu mendapatkan gambaran yang lebih akurat tentang kemampuan dan kehandalan model dalam mengklasifikasikan data fungsional dan nonfungsional.

Tabel 1. Data Uji Kebutuhan Fungsional dan Non Fungsional.

No	Kebutuhan	Indikator	Kategori
1.	Mendaftar akun baru	Otentikasi Pengguna	F
2.	Mengakses daftar kursus	Penugasan dan Proyek	F
3.	Menyediakan konten interaktif	Manajemen Konten	F
4.	Menyediakan forum diskusi	Forum Diskusi	F
5.	Akses ulang materi pembelajaran	Pelacakan Aktivitas	F
6.	Waktu respon cepat	Kecepatan	NF
7.	Keamanan data terjaga	Keamanan	NF
8.	Tersedia 24/7	Kinerja	NF
9.	Tampilan antarmuka <i>user-friendly</i> dan responsif	Antarmuka Pengguna	NF
10.	Ketersediaan sistem dipertahankan dengan teknologi replikasi data dan backup secara teratur	Integrasi	NF
...	...	...	...
...	...	...	...
20.	Memiliki fitur pelacakan kemajuan belajar pengguna	Pelacakan Aktivitas	F
21.	Menyediakan materi pembelajaran yang mudah dipahami	Multi-bahasa	F
22.	Menyediakan fitur pencarian materi pembelajaran	Pencarian Efisien	F
23.	Sistem harus dapat menjaga keamanan data pengguna dan tidak mudah diretas	Keamanan	NF

24.	Sistem harus dapat melakukan backup secara otomatis	Ketersediaan	NF
25.	Aplikasi harus mendukung berbagai jenis file dokumen	Ketersediaan	NF

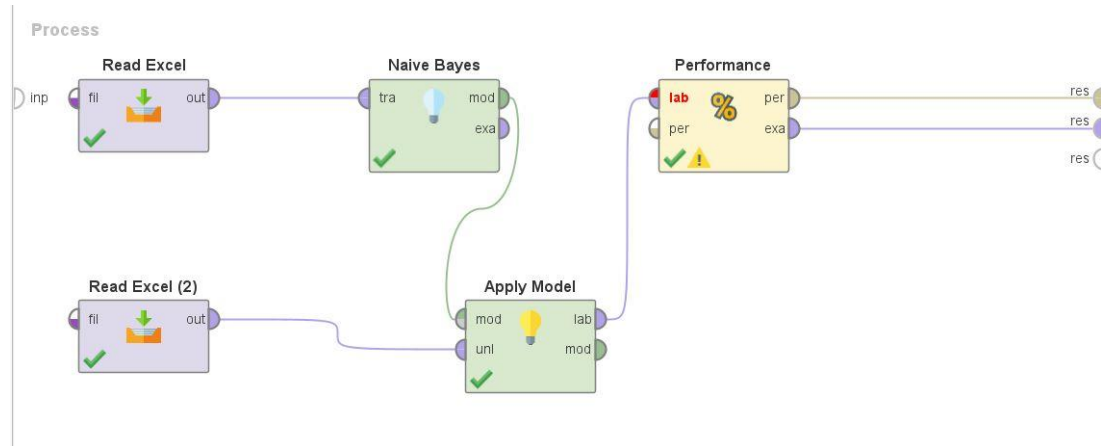
Tabel 2. Data Latih Kebutuhan Fungsional dan Non Fungsional.

No	Kebutuhan	Indikator	Kategori
1.	Aplikasi harus memiliki sistem autentikasi dan otorisasi	Autentikasi	F
2.	Sistem harus dapat menampilkan laporan penggunaan secara berkala	pelaporan	F
3.	Sistem harus dapat melakukan backup secara otomatis	penyimpanan data	F
4.	Sistem harus dapat memperbarui informasi pengguna yang terdaftar	Manajemen Data Pengguna	F
5.	Sistem harus memiliki fitur untuk mengirim email konfirmasi	Pesan Antar Pengguna	F
6.	Sistem perlu memiliki fitur pencarian	Pencarian Efisien	F
7.	Sistem harus dapat menampilkan laporan penjualan harian	Ketersediaan	NF
8.	Sistem harus memiliki fitur untuk memproses pembayaran secara online	Dukungan Teknis	NF
9.	Tampilan website harus responsif dan mudah diakses	Responsif/Adaptif	NF
10.	Data harus tersimpan dengan aman dan terenkripsi	Keamanan	NF
11.	Tidak ada gangguan jaringan saat penggunaan platform	Keandalan	NF
12.	Tampilan antarmuka harus <i>user-friendly</i>	Antarmuka Pengguna	NF
13.	Tampilan website harus sesuai dengan tema kampus	Antarmuka Pengguna	NF

Hasil Penelitian

Proses klasifikasi pada RapidMiner menggunakan metode Naïve Bayes dimana data klasifikasi user requirements ini akan dicocokkan antara data testing dengan data training yang telah ditemukan sebelumnya.

Pada tampilan process langkah yang harus dilakukan yaitu dengan masukan data training dan data testing, selanjutnya masukan operator Naïve Bayes, tahap terakhir sambungkan kabel seperti Gambar 3.



Gambar 3. Klasifikasi dengan RapidMiner

Tabel prediksi pada klasifikasi user requirements e-learning dengan metode Naive Bayes yang di implemestasikan pada tools RapidMiner, berisi informasi tentang hasil prediksi dan tingkat kepercayaan model dalam memprediksi label atau kelas pada setiap sampel data. Tabel prediksi ini berisi beberapa kolom penting, yaitu:

1. ID: Kolom ini berisi nomor unik dari setiap sampel data.
2. Kategori: Kolom ini berisi label aktual atau kelas asli dari setiap sampel data.
3. Predicted: Kolom ini berisi label atau kelas yang diprediksi oleh model untuk setiap sampel data.
4. Confidence: Kolom ini berisi tingkat kepercayaan atau probabilitas bahwa model benar dalam memprediksi label atau kelas pada setiap sampel data.
5. Probability Distribution: Kolom ini berisi distribusi probabilitas untuk setiap kelas yang diprediksi oleh model.

Tabel 3. Data Hasil Prediksi Naïve bayes menggunakan Rapidminer.

No	Kebutuhan	Indikator	Fungsional	Non-Fungsional	Prediction Kategori
1.	Mendaftar akun baru	Otentikasi Pengguna	F	0,553540918	0,446459082
2.	Mengakses daftar kursus	Penugasan dan Proyek	F	0,553540918	0,446459082
3.	Menyediakan konten interaktif	Manajemen Konten	F	0,553540918	0,446459082

4.	Menyediakan forum diskusi	Forum Diskusi	F	0,553540918	0,446459082
5.	Akses ulang materi pembelajaran	Pelacakan Aktivitas	F	0,553540918	0,446459082
6.	Waktu respon cepat	Kecepatan	NF	0,553540918	0,446459082
7.	Keamanan data terjaga	Keamanan	NF	0,076345974	0,923654026
8.	Tersedia 24/7	Kinerja	NF	0,553540918	0,446459082
9.	Tampilan antarmuka <i>user-friendly</i> dan responsif	Antarmuka Pengguna	NF	0,02802557	0,97197443
10.	Ketersediaan sistem dipertahankan dengan teknologi replikasi data dan backup secara teratur	Integrasi	NF	0,553540918	0,446459082
...	...	...			...
...	...	...			...
32.	Notifikasi real-time untuk pembaruan penting	Notifikasi	F	0,553540918	0,446459082
33.	Sistem rekomendasi konten yang relevan dengan minat pengguna	Dukungan Teknis	NF	0,076345974	0,923654026
34.	Fitur bookmark untuk menyimpan dan mengakses konten favorit	Ketersediaan	NF	0,076345974	0,923654026
35.	Kemampuan untuk mengatur jadwal belajar yang fleksibel	Personalisasi Konten	F	0,553540918	0,446459082
36.	Tampilan antarmuka harus mudah digunakan	Antarmuka Pengguna	NF	0,02802557	0,97197443

Berdasarkan performance vector tersebut, terdapat beberapa nilai yang menunjukkan performa dari suatu model klasifikasi. Berikut adalah pembahasan dari nilai-nilai tersebut:

Tabel 4. Data Hasil Akurasi Naïve bayes menggunakan Rapidminer.

	True F	True NF	Class Precision
Pred. F	12	5	70.59%
Pred.NF	0	8	100.00%
Class recall	100.00%	61.54%	

Confussion Matrix

Matriks konfusi digunakan untuk menunjukkan hasil prediksi model pada setiap kelas (Markoulidakis & Markoulidakis, 2024). Matriks ini terdiri dari empat angka, yaitu True Positive (TP), False Positive (FP), False Negative (FN), dan True Negative (TN) (Riehl et al., 2023). Dalam kasus ini, matriks konfusi menunjukkan hasil prediksi model untuk dua kelas, yaitu "F"(Fungsional) dan "NF"(Non Fungsional).

Akurasi

Akurasi adalah ukuran persentase dari prediksi yang benar dibandingkan dengan keseluruhan jumlah sampel (El Fiorenza Caroline et al., 2019). Dalam kasus ini, akurasi sebesar 88.89% menunjukkan bahwa model berhasil mengklasifikasikan 88.89% sampel dengan benar. Jika dihitung secara matematis maka:

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

$$\text{Perhitungan Akurasi} = \frac{(21 + 11)}{(21 + 11 + 4 + 0)} = \frac{32}{36} = 0.8889 \text{ (88.89\%)}$$

Precision

Presisi adalah ukuran persentase dari prediksi positif yang benar (True Positive) dibandingkan dengan total prediksi positif (True Positive + False Positive) (Rahayu & Yamasari, 2024). Dalam kasus ini, presisi sebesar 100.00% menunjukkan bahwa model tidak membuat kesalahan dalam memprediksi kelas positif "NF" (Non-Fungsional). Jika dihitung secara matematis maka:

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

$$\text{Perhitungan Presisi} = \frac{11}{(11 + 4)} = \frac{11}{5} = 0.7333 \text{ (73.33\%)}$$

Recall

Recall (juga dikenal sebagai Sensitivitas atau True Positive Rate) adalah ukuran persentase dari prediksi positif yang benar (True Positive) dibandingkan dengan total jumlah sampel aktual yang positif (True Positive + False Negative) (Rahayu & Yamasari, 2024). Dalam kasus ini, recall sebesar 73.33% menunjukkan bahwa model berhasil

mendeteksi 73.33% dari seluruh sampel sebenarnya yang termasuk dalam kelas "NF" (Non-Fungsional). Jika dihitung secara matematis maka :

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

$$\text{Perhitungan Recall} = \frac{11}{(11 + 0)} = \frac{11}{11} = 1.0000 \text{ (100.00\%)}$$

Recall

AUC adalah ukuran yang menggambarkan kemampuan model dalam membedakan antara kelas positif dan negatif menggunakan kurva Receiver Operating Characteristic (ROC). Terdapat tiga nilai AUC yang diberikan: AUC (optimistic), AUC, dan AUC (pessimistic). Semua nilai AUC ini berkaitan dengan kelas positif "NF" (Non-Fungsional).

- AUC (optimistic): 0.987
- AUC: 0.892
- AUC (pessimistic): 0.797

Perhitungan AUC dilakukan dengan menggunakan kurva Receiver Operating Characteristic (ROC), yang menggambarkan hubungan antara True Positive Rate (TPR) dan False Positive Rate (FPR) pada berbagai threshold[11]. Perhitungan AUC melibatkan perhitungan luas area di bawah kurva ROC. Dalam hal ini, semua nilai AUC yang diberikan berkaitan dengan kelas positif "NF" (Non-Fungsional), namun rumus tidak diberikan secara langsung dalam deskripsi. Perhitungan AUC memerlukan informasi lebih lanjut mengenai nilai TPR dan FPR pada berbagai threshold.

Dalam rangka untuk menghitung AUC dengan lebih rinci, informasi mengenai nilai TPR dan FPR pada berbagai threshold akan diperlukan. Dengan menggunakan informasi tersebut, kurva ROC dapat dibangun dan AUC dapat dihitung.

Secara keseluruhan, model yang dievaluasi memiliki akurasi yang tinggi (88.89%) dan presisi yang sempurna dalam memprediksi kelas positif "NF" (Non-Fungsional). Namun, recall model dapat ditingkatkan untuk lebih baik. Nilai AUC menunjukkan bahwa model memiliki kemampuan yang baik hingga sangat baik dalam membedakan antara kelas "NF"(Non-Fungsional) dan "F" (Fungsional) berdasarkan kurva ROC.

Kesimpulan

Dalam pengembangan sistem e-learning, penting untuk memperhatikan dan mengklasifikasikan kebutuhan pengguna dengan baik. Metode Naive Bayes digunakan untuk klasifikasi kebutuhan pengguna dalam penelitian e-learning. Penggunaan RapidMiner sebagai alat analisis data terbukti efektif. Evaluasi performa model klasifikasi membantu memahami sejauh mana kebutuhan pengguna terpenuhi. Penelitian ini berpotensi memberikan manfaat dalam meningkatkan akses pembelajaran dan mengembangkan platform e-learning yang berkualitas.

Daftar Pustaka

- Budake, R. D., Bhoite, S. D., & Kharade, K. G. (2024). Machine Learning-Based Identification as Well as Classification of Functional and Non-functional Requirements (pp. 501–513). https://doi.org/10.1007/978-981-99-6690-5_38
- Diantoro, A., & Santoso, I. B. (2017). Eggs Fertilities Detection System on the Image of Kampung Chicken Egg Using Naive Bayes Classifier Algorithm. *MATICS*, 9(2), 53. <https://doi.org/10.18860/mat.v9i2.4198>
- El Fiorenza Caroline, J., Parmar, P., Tiwari, S., Dixit, A., & Gupta, A. (2019). Accuracy Prediction Using Analysis Methods and F-Measures. *Journal of Physics: Conference Series*, 1362(1), 012040. <https://doi.org/10.1088/1742-6596/1362/1/012040>
- Kong, W.-E., Haw, S.-C., Palanichamy, N., & Rahman, S. H. A. (2024). An e-Learning Recommendation System Framework. *International Journal on Advanced Science, Engineering and Information Technology*, 14(1), 10–19. <https://doi.org/10.18517/ijaseit.14.1.19043>
- Kumar, R., Krishna Goswami, B., Motiram Mhatre, S., & Agrawal, S. (2024). Naive Bayes in Focus: A Thorough Examination of its Algorithmic Foundations and Use Cases. *International Journal of Innovative Science and Research Technology (IJISRT)*, 2078–2081. <https://doi.org/10.38124/ijisrt/IJISRT24MAY1438>
- Li, H. (2024). The Naïve Bayes Method. In *Machine Learning Methods* (pp. 67–75). Springer Nature Singapore. https://doi.org/10.1007/978-981-99-3917-6_4
- Markoulidakis, I., & Markoulidakis, G. (2024). Probabilistic Confusion Matrix: A Novel Method for Machine Learning Algorithm Generalized Performance Analysis. *Technologies*, 12(7), 113. <https://doi.org/10.3390/technologies12070113>
- Rahayu, S., & Yamasari, Y. (2024). Klasifikasi Penyakit Stroke dengan Metode Support Vector Machine (SVM). *Journal of Informatics and Computer Science*, 05.
- Riehl, K., Neunteufel, M., & Hemberg, M. (2023). Hierarchical confusion matrix for classification performance evaluation. *Journal of the Royal Statistical Society Series C: Applied Statistics*, 72(5), 1394–1412. <https://doi.org/10.1093/jrssc/qlad057>
- Sani, J., Kamal, M. M., Biswas, T. K., Chowdhury, S., Roy, S., & Sarwar, S. (2024). Technologies Used in Education. *International Journal For Multidisciplinary Research*, 6(3). <https://doi.org/10.36948/ijfmr.2024.v06i03.22020>
- Santoso, I. B., Informatika, J. T., & Pendahuluan, I. (n.d.). Deteksi Non-RTH(Ruang Terbuka Hijau) Kota Malang Berbasis Citra Google Earth Dengan Menggunakan Naïve Bayes Classifier. 59–64.
- Senan, S., & Tasci, S. K. (2024). A Comprehensive Analysis of Data Mining Tools for Biomedical Data Classification (pp. 216–231). <https://doi.org/10.4018/979-8-3693-1062-5.ch012>
- Serwornoo, M. Y. W., Danso, S., Azanu, B., Semarco, S. K. M., & Aidoo, E. A. K. (2024). Use of Digital Platforms Among University Students: A Systematic Literature Review. *Qeios*. <https://doi.org/10.32388/SQKGT5.2>
- Veziroğlu, M., Veziroğlu, E., & Bucak, İ. Ö. (2024). Performance Comparison between Naive Bayes and Machine Learning Algorithms for News Classification. In *Bayesian Inference - Recent Trends*. IntechOpen. <https://doi.org/10.5772/intechopen.1002778>

- Wienand, M., Wulfert, T., & Hoang, H. (2024). Design principles for e-learning platforms featuring higher-education students' enterprise systems end-user training. *Discover Education*, 3(1), 82. <https://doi.org/10.1007/s44217-024-00165-z>
- Zahri, M. H., Sunge, A. S., & Zy, A. T. (2024). Analysis of Product Sales in the Application of Data Mining with Naive Bayes Classification. *Journal of Computer Networks, Architecture and High Performance Computing*, 6(3), 1213–1223. <https://doi.org/10.47709/cnahpc.v6i3.4255>
- Zulpukarova, D. I., Abdukaimova, A. Z., & Alieva, K. U. (2024). The use of online educational platforms in teaching. *Bulletin of Issyk-Kul University*. <https://doi.org/10.69722/1694-8211-2024-56-66-73>