

DOI <http://dx.doi.org/10.36722/sst.v10i2.3089>

Prediksi Peringkat Akreditasi BAN PT Program Studi Sarjana Rumpun Ilmu Komputer Menggunakan Klasifikasi *Machine Learning*

Budi Aribowo¹, Budi Tjahjono^{1*}, Gerry Firmasnyah¹, Agung Mulyo Widodo¹

¹Magister Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Esa Unggul
Jl. Arjuna Utara No. 9, Jakarta, 11510.

Penulis untuk Korespondensi/E-mail: budi.tjahono@esaunggul.ac.id

Abstract – Accreditation ranking is one of the causes and indicators chosen by prospective students when choosing a study program in higher education. From the data collected, only 5% of study programs in the Computer Science group have a Superior accreditation rating and an A accreditation rating in LLDikti Region III Jakarta. So it is necessary to know the factors that influence the accreditation ranking. The machine learning methodology used in this approach is K-Nearest Neighbors (KNN) and from the data obtained there are 6 factors that can be strongly suspected to influence the study program accreditation value. The four machine learning models, namely KNN, Gaussian Naïve Bayes Decision Tree and Logistic Regression, it was found that the KNN machine learning model with 2 input variables had the highest AUC value, namely 84.38%. Meanwhile, from the model simulation run by KNN machine learning, 2 input variables can produce relatively accurate prediction results. And the results of cross validation with 10 folds support the selected machine learning with an accuracy level of 80%. In general, the KNN machine learning model with 2 input variables was able to predict the accreditation rating of Study Programs, especially from the Computer Science Cluster.

Abstrak – Peringkat akreditasi merupakan salah satu sebab dan indikator yang dipilih oleh calon mahasiswa dalam memilih suatu program studi di perguruan tinggi. Berdasarkan data yang dikumpulkan hanya terdapat 5% program studi pada rumpun Ilmu Komputer yang memiliki peringkat akreditasi Unggul dan peringkat akreditasi A di LLDikti Wilayah III Jakarta. Sehingga demikian perlu diketahui faktor-faktor yang mempengaruhi peringkat akreditasi. Metodologi *machine learning* yang digunakan dalam pendekatan ini adalah *K-Nearest Neighbors* dan dari data yang berhasil diperoleh terdapat 6 faktor yang dapat diduga kuat mempengaruhi nilai akreditasi. Berdasarkan keempat model *machine learning* yaitu KNN, *Gaussian Naïve Bayes*, *Decision Tree* dan Regresi Logistik didapatkan model *machine learning* KNN 2 variabel input memiliki nilai AUC tertinggi yaitu sebesar 84,38%. Serta dari simulasi model yang dijalankan *machine learning* KNN 2 variabel input dapat menghasilkan hasil prediksi yang relatif tepat, dan hasil *cross validation* dengan 10 *fold* mendukung *machine learning* yang terpilih dengan tingkat akurasi sebesar 80%. Secara umum model *machine learning* KNN dengan 2 variabel input dapat memprediksi peringkat akreditasi Program Studi terutama dari Rumpun Ilmu Komputer.

Keywords – Accreditation, Area Under Curve (AUC), Department of School, Kfold Cross Validation, Machine Learning.

PENDAHULUAN

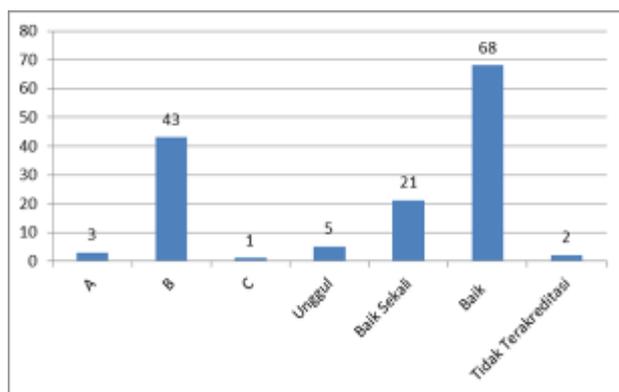
Akreditasi Program Studi (APS) merupakan suatu kegiatan untuk menjamin kelayakan suatu program studi di sebuah universitas

sebagaimana yang dinyatakan pada Peraturan Menteri Pendidikan dan Kebudayaan Republik Indonesia Nomor 5 Tahun 2020 tentang Akreditasi Perguruan Tinggi ayat (2) yang berbunyi: “Akreditasi Program Studi adalah kegiatan penilaian

untuk menentukan kelayakan Program Studi”. Saat ini menemukan suatu pendidikan tinggi yang layak merupakan tantangan tersendiri bagi kebanyakan orang tua dan siswa [1].

Hasil penelitian [2] menjelaskan bahwa kultur kualitas dan kinerja suatu perguruan tinggi akan mempengaruhi nilai akreditasi baik secara langsung maupun tidak langsung. Nilai akreditasi program studi menjadi penting untuk *sustainability* suatu program studi karena menjadi jaminan bagi masyarakat awam untuk mendapatkan pendidikan yang berkualitas. Sehingga disebutkan bahwa akreditasi merupakan sebuah proses dimana lembaga resmi eksternal menilai kepatuhan institusi pendidikan dengan kriteria, standar dan prosedur dengan tujuan utama untuk menjamin semua institusi menghasilkan lulusan yang *capable* secara merata [3], maka dari itu program studi perlu mengevaluasi diri dan mengetahui *positioning*nya serta memiliki waktu yang cukup untuk melakukan peningkatan nilai akreditasi melalui prediksi nilai akreditasi

Data BAN PT memperlihatkan hanya terdapat sekitar 5% Program Studi Rumpun Ilmu Komputer yang mendapatkan nilai akreditasi A dan Unggul di Layanan Lingkungan Pendidikan Tinggi Wilayah III sebagaimana data tersaji pada gambar 1.



Gambar 1. Peringkat Akreditasi Prodi Rumpun Ilmu Komputer LLDikti Wilayah III

Pada data gambar 1 dapat diketahui masih banyak program studi di rumpun ilmu komputer yang belum terakreditasi unggul, maka dari itu program studi perlu mengevaluasi diri dan mengetahui *positioning*nya serta memiliki waktu yang cukup untuk melakukan peningkatan nilai akreditasi melalui prediksi nilai akreditasi terutama untuk mendapatkan peringkat akreditasi Unggul. Dengan mengetahui faktor-faktor yang mempengaruhi nilai peringkat akreditasi program studi dapat membuat

rencana dan prioritas program kerja strategis untuk mendapatkan peringkat akreditasi yang lebih baik. Sehingga demikian tujuan dari penelitian ini adalah mendapatkan Model *Machine Learning* yang dapat memprediksi akreditasi program studi terutama pada rumpun Ilmu Komputer di Lembaga Layanan Pendidikan Tinggi Wilayah III.

METODE

Pengumpulan data dilakukan melalui 3 situs yaitu: (1) Badan Akreditasi Nasional Perguruan Tinggi (<https://www.banpt.or.id/>) berupa data akreditasi, (2) Pangkalan Data Dikti (<https://pddikti.kemdikbud.go.id/>) berupa data jumlah dosen *homebase*, dosen penghitung rasio, dosen dengan jenjang jabatan akademik (jja) dan jumlah mahasiswa serta (3) SINTA (<https://sinta.kemdikbud.go.id/>) berupa data nilai Sinta *overall* dan Sinta *3 years*.

Data yang telah dikumpulkan kemudian dilakukan proses *preprocessing*. Suyanto [4] menyebutkan terdapat 3 tujuan melakukan prapemrosesan data yaitu (1) Mempermudah memahami data sehingga mempermudah pemilihan teknik dan metode *Data Mining* yang tepat, (2) Meningkatkan kualitas data sehingga hasil *Data Mining* menjadi lebih baik dan (3) Meningkatkan efisiensi dan kemudahan proses penambahan data [4]. *Preprocessing* data yang dilakukan berupa data *cleaning*, normalisasi data serta data *transformation*.

Data cleaning dilakukan dengan cara menghilangkan data yang memiliki nilai *null*. Hal ini dilakukan agar data dapat diolah dengan baik terutama pada tahapan *feature selection*. Sementara itu proses normalisasi data dilakukan dengan menggunakan metode **MinMax Scaler** dengan menggunakan *library* yang tersedia pada Python untuk menyamakan skala pada data variabel *input*. Sedangkan transformasi data dilakukan menggunakan sintaksis **LabelEncoder()** untuk data variabel *output* dari tipe data string menjadi *binary integer*.

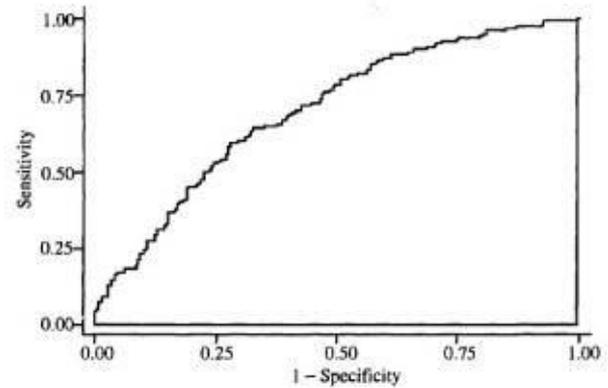
Feature selection kemudian dilakukan untuk mengetahui faktor-faktor yang terkuat yang dapat mempengaruhi variabel *output*. Metode *feature selection* yang digunakan adalah ANOVA atau *analysis of variance* dan statistik uji yang digunakan adalah statistik uji F. Pada dasarnya nilai uji F merupakan suatu teknik yang mengukur diskriminasi dua set bilang real baik bersifat

numerik maupun kategorik. Suatu fitur yang memiliki nilai F yang besar adalah fitur yang sangat diskriminatif [5]. Sementara itu Wahyuni [6] menyebutkan bahwa seleksi fitur *F-Score* memiliki kemampuan yang sangat baik dalam memilih fitur-fitur yang signifikan terhadap klasifikasi.

Setelah mendapatkan faktor-faktor yang mempengaruhi peringkat akreditasi atau variabel input maka selanjutnya dilakukan pemisahan data berupa data *training* dan data *testing*. Kemudian [7] menyebutkan bahwa *data training* merupakan sekumpulan data yang memiliki atribut label/kelas yang digunakan oleh mesin untuk mengenal karakteristik kumpulan data sehingga menghasilkan sebuah pola atau model data. Sementara itu *data testing* adalah sekumpulan data yang juga memiliki label/kelas yang digunakan untuk menguji ketepatan pola/model dalam mengklasifikasikan data *testing*.

Data *training* yang dihasilkan kemudian dilatih dengan menggunakan 4 *machine learning* klasifikasi yaitu *K-Nearest Neighbors*, *Gaussian Naïve Bayes*, *Decision Tree* dan *Regresi Logistik*. Metode Klasifikasi adalah sebuah model dalam *Data Mining* dimana *classifier* dikonstruksi untuk memprediksi *categorical label* [8]. Arhami dan Nasir [9] menyebutkan bahwa label kelas yaitu variabel dependen dari model merupakan variabel kategori. Bagian sangat penting dalam data *mining* adalah teknik klasifikasi, teknik yang mempelajari sekumpulan data sehingga dihasilkan aturan yang bisa mengklasifikasikan atau mengenali data baru yang belum pernah dipelajari [10]. Dengan mengeksplorasi secara sistematis dan menggunakan beberapa model *machine learning*, pengambilan keputusan akan menjadi lebih baik [11].

Hasil latih keempat *machine learning* kemudian dapat diukur tingkat akurasi menggunakan luas area (*Area Under Curve*) dari *Receiver Operating Curve* atau ROC untuk dibandingkan sehingga mendapatkan nilai akurasi yang paling tinggi. Kurva ROC merupakan hasil plot antara *true signal* (*sensitivity*) dan *false signal*. Rentang dari luas area di bawah kurva ROC adalah nol sampai dengan 1 (atau 100%). Luas area di bawah kurva mampu mengukur seberapa besar kemampuan model mendiskriminasi observasi yang mengalami kejadian sukses dan tidak sukses [12]. Berikut gambar 2 yang menunjukkan kurva ROC.



Gambar 2. Receiver Operating Curve [13]

Luas area di bawah kurva ROC sebagaimana gambar 2 atau AUC secara umum dapat menggunakan pendekatan integral terhadap fungsi ROCnya dengan batas limit bawah 0 dan batas limit atas 1 [14] :

$$AUC = \int_0^1 ROC(u) du \quad (1)$$

Kategori hasil nilai AUC atau luas area di bawah kurva ROC dapat dilihat pada tabel 1 [15].

AUC	Kategori
$0,90 < AUC \leq 1,00$	<i>Excellent</i>
$0,80 < AUC \leq 0,90$	<i>Good</i>
$0,70 < AUC \leq 0,80$	<i>Fair</i>
$0,60 < AUC \leq 0,70$	<i>Poor</i>
$0,50 < AUC \leq 0,60$	<i>Failed</i>

Pada tabel 1 dapat dikatakan jika luas area di bawah kurva ROC di bawah 0,5 atau 50% maka model statistik yang dievaluasi memiliki tingkat keakuratan yang sangat rendah dan mengindikasikan bahwa model tersebut sangat buruk jika digunakan [16].

Hasil dari perbandingan nilai AUC untuk masing-masing *machine learning* kemudian dipilih nilai AUC yang paling tinggi. Proses memvalidasi hasil AUC dilakukan dengan *cross validation* menggunakan *KFold Cross validation*. Dimana *cross validation* sendiri digunakan untuk mengukur kinerja algoritma KNN secara lebih umum dengan membagi *dataset* menjadi data *training* dan data *testing* dimana hal ini dapat membantu mengidentifikasi apakah model memiliki tingkat akurasi yang baik [17].

Seluruh kegiatan proses pengolahan data menggunakan Bahasa Pemrograman Python dengan *code editor* atau *Integrated Development Environment* (IDE) yang menggunakan Jupyter

Notebook. Python sendiri dikembangkan oleh Guido van Rossum seorang *programmer* berkebangsaan Belanda pada tahun 1980an dan *released* secara resmi pada tahun 1991 [18]. Berkenaan dengan Python dalam kegiatan *data mining* beberapa aplikasi turunan atau berbasis Python seperti Propytha disebutkan sebagai *tool* yang sangat baik untuk aplikasi *machine learning* dan *deep learning* [19]. Terdapat pula aplikasi lain yang berbasis python yang disebut sebagai PyMLDA atau *Python Machine Learning for Damage Assessment* [20]

HASIL DAN PEMBAHASAN

Data yang telah dikumpulkan dikelompokkan menjadi variabel *input* dan variabel *output* yang terlihat pada tabel 2.

Tabel 2. Variabel Input dan Variabel Output Penelitian

Variabel Input	Variabel Output
Dosen Homebase	Unggul/Menuju Unggul
Dosen JJA	Belum Unggul
Dosen Penghitung Rasio	
Jumlah Mahasiswa	
SINTA Overall	
SINTA 3 Years	

Variabel *output* pada tabel 2, dibagi menjadi 2 bagian yaitu Unggul/Menuju Unggul yaitu prodi dengan akreditasi Unggul, A, dan Baik Sekali. Sementara itu untuk variabel *output* Belum Unggul terdiri dari Prodi dengan peringkat akreditasi Baik, B dan C. Sementara data jumlah program studi yang siap diolah dan setelah melalui *preprocessing* data ditampilkan pada tabel 3.

Tabel 3. Jumlah Data Prodi dan Kategorinya

Akreditasi	Jumlah
Unggul, A dan Baik Sekali	27
Baik, B dan C (Belum Unggul)	89
Total	116

Hasil data *cleaning* pada tabel 3 kemudian dilanjutkan tahapan berikutnya adalah melakukan reduksi data atau *feature selection* terhadap variabel input dengan menggunakan metode ANOVA serta *library* python `from sklearn.feature_selection import Select KBest, f_classif`, kemudian didapatkan hasil nilai F dan p-value pada tabel 4.

Tabel 4. Hasil Feature Selection

Variabel Input	p-value
SINTA Overall	0,0003
SINTA 3 Years	0,0004
Dosen Homebase	0,0455

Variabel Input	p-value
Dosen Penghitung Rasio	0,0657
Dosen JJA	0,0852
Jumlah Mahasiswa	0,1624

Hasil tabel 4 didapatkan variabel terkuat yang mempengaruhi nilai akreditasi adalah variabel SINTA Overall dan Sinta 3 Years dengan masing-masing nilai *value* di bawah 1%. Hal ini menunjukkan kedua variabel secara signifikan berpengaruh terhadap kategori peringkat akreditasi.

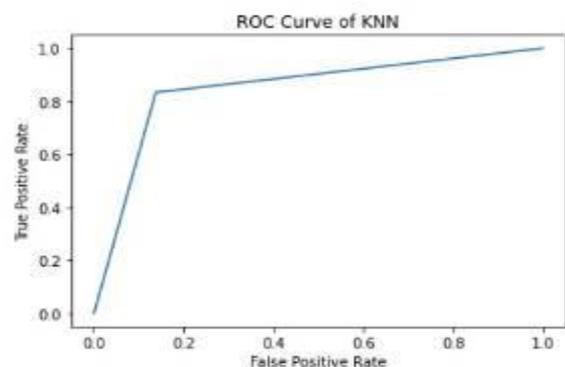
Dua variabel yang signifikan tersebut selanjutnya digunakan dalam pemodelan keempat *machine learning* yang dipakai yaitu *K-Nearest Neighbors*, *Gaussian Naïve Bayes*, *Decision Tree* serta Regresi Logistik. *Split* data *training* dan data *testing* digunakan pembagian 70% data *training* dan 30% data *testing* dan data *testing* kemudian dilatih berdasarkan *machine learning* yang dipilih dan dikonfirmasi pada IDE Jupyter Notebook, yang terlihat pada gambar 3.

```
#Train the model
from sklearn.neighbors import KNeighborsClassifier
knn = KNeighborsClassifier(n_neighbors = 1)
knn.fit(X_train, y_train.values.ravel())
```

KNeighborsClassifier
KNeighborsClassifier(n_neighbors=1)

Gambar 3. Konfirmasi Data Latih dengan KNN

Hal yang sama dari gambar 3 dilakukan untuk *machine learning* *Gaussian Naïve Bayes*, *Decision Tree* dan Regresi Logistik, sedangkan untuk tingkat akurasi digunakan nilai AUC yang didapatkan dari kurva ROC dengan contoh *machine learning* KNN pada gambar 4.



Gambar 4. Kurva AUC Machine Learning KNN

Luas AUC yang ditunjukkan pada gambar 4 adalah sebesar 84,38%, begitu pula dilakukan hal sama dengan ketiga *machine learning* lainnya sehingga

demikian mendapatkan hasilnya secara lengkap pada tabel 5.

Tabel 5. Luas Area *Under Curve Machine Learning* yang Digunakan

<i>Machine Learning</i>	Nilai AUC	Kategori Diskriminan
KNN (n = 1)	84,38%	Good
Naïve Bayes	63,43%	Poor
Decision Tree	63,19%	Poor
Logistic Regression	72,69%	Fair

Tabel 5 menunjukkan bahwa *machine learning* KNN memiliki tingkat akurasi paling tinggi dengan nilai AUC sebesar 84,38%, dan untuk memvalidasi hasil tersebut maka digunakan Metode *KFold Cross Validation* dengan lipatan atau *fold* sebanyak 10 kali lipatan. Hasil dari perhitungan *KFold Cross Validation* dapat dilihat pada tabel 6.

Tabel 6. Nilai *KFold Cross Validation Machine Learning* KNN

<i>Fold</i>	<i>Cross Validation Score</i>	<i>Mean</i>
1	0,80	0,80
2	0,60	
3	0,78	
4	0,78	
5	0,78	
6	0,78	
7	0,89	
8	1,00	
9	0,67	
10	0,89	

Dengan menunjukkan nilai rata-rata *KFold Cross Validation* dari tabel 6 sebesar 80%, maka dapat dinyatakan bahwa model *machine learning* KNN adalah valid.

KESIMPULAN

Matriks Penilaian Kinerja Program Studi dan Suplemen Sarjana LAM Infokom yang dikeluarkan tahun 2022 untuk Kriteria Penelitian dan Pengabdian Masyarakat di SINTA memberikan kontribusi total hanya sebesar 7%, namun secara timbal balik juga memberikan kontribusi kepada kriteria lain seperti Sumber Daya Manusia (7,5%), Keuangan (5,5%) juga terutama memberikan kontribusi kepada kriteria Capaian dan Luaran yang memberikan kontribusi paling besar yaitu sebanyak 52%, terutama pada butir jumlah publikasi, jumlah penelitian, jumlah Hak Kekayaan Intelektual (HKI),

jumlah pengabdian masyarakat yang diadopsi masyarakat serta jumlah pengabdian masyarakat yang mendapatkan HKI.

Oleh karena itu *machine learning* KNN (n = 1) dengan 2 variabel yaitu nilai SINTA *Overall* dan Sinta 3 *Years* dapat memberikan prediksi yang baik bagi peringkat akreditasi program studi pada rumpun Ilmu Komputer dengan tingkat akurasi sebesar 84,38%, serta model telah divalidasi dengan menggunakan *KFold Cross Validation* dengan nilai rata-rata sebesar 80%.

REFERENSI

- [1] S. A. Makhoul, "Higher Education Accreditation, Quality Assurance, and Their Impact to Teaching and Learning Enhancement" *Journal of Economic and Administrative Sciences*, Vol. 35, No. 4, pp. 235-250, 2019, doi: 10.1108/JEAS-08-2018-0092
- [2] S. Iqbal, C. A. B. Taib, and M. R. Razalli, "The Effect of Accreditation on Higher Education Performance Through Quality Culture Mediation: The Perceptions of Administrative and Quality Managers" *The TQM Journal*. Vol. 36, No.2, pp. 572-592, 2024.
- [3] S. Alenezi et. al, "Impact of External Accreditation on Students Performance : Insight from a Full Accreditation Cycle", *Heliyon* 9, e15815, Volume 9, Issue 5, 2023.
- [4] Suyanto, "Data Mining untuk Klasifikasi dan Klasterisasi Data", Penerbit Informatika, Bandung, Cetakan Pertama, 2019.
- [5] T. Yulianti, H. D. Fitriawan, H. Septama, I. Oktadiani, "Seleksi Fitur F-Score untuk Klasifikasi Tingkat Kesegaran Daging Sapi Lokal Menggunakan Ekstraksi Fitur Citra", *Prosiding Seminar Nasional SINTA FT UNILA*, Vol. 2, ISBN: 2655-2914, 2019.
- [6] E. S. Wahyuni, "Penerapan Metode Seleksi Fitur Untuk Meningkatkan Hasil Diagnosis Kanker Payudara" *Jurnal Simetris*, Vol. 7, No. 1, ISSN : 2252-4983, 2016.
- [7] W. Musu, A. Ibrahim, Heriadi, "Pengaruh Komposisi Data Training dan Testing terhadap Akurasi Algoritma C4.5", *Prosiding Seminar Ilmiah Sistem Informasi dan Teknologi Informasi*, Vol. X, No. 1, Hal. 186-195, 2021.
- [8] R. T. Vlandari, "Data Mining : Teori dan Aplikasi Rapid Miner", Penerbit Gava Media, Cetakan I, 2017.

- [9] M. Arhami dan M. Nasir, "Data Mining Algoritma dan Implementasi", Penerbit ANDI, Yogyakarta, 2020.
- [10] Suyanto, "Data Mining Untuk Klasifikasi dan Klasterisasi Data", Penerbit Informatika, Bandung, Cetakan Pertama, ISBN : 978-602-6232-97-7, 2019.
- [11] J. Jumana et. al. "Fake News Detection Using Python and Machine Learning", *Procedia Computer Science*, 233 (2024) 763-771, 2024.
- [12] M. R. F. Nur dan S. I. Oktora, "Analisis Kurva ROC pada Model Logit Dalam Pemodelan Determinan Lansia Bekerja di Kawasan Timur Indonesia", *Indonesian Journal of Statistics and Its Application*, Vol 4, No. 1, hal. 116-135. eISSN : 2599-0802, 2020.
- [13] D. W. Hosmer and S. Lemeshow, "Applied Logistics Regression", John Wiley & Son, Second Edition, Print ISBN : 9780471356325, 2000.
- [14] K. Gajowniczek and T. Zabkowski, "Estimating the ROC Curve and Its Significance for Classification Model's Assesment. Quantitative Methods in Economics", Vol. XV, No. 2, p. 382-39, 2014.
- [15] D. G. Kleinbaum and M. Klein, "Logistic Regression : A Self Learning Text", (3rd ed), New York (US), Springer Verlag, 2010.
- [16] K. H. Zou, J. O'Malley, and L. Mauri, "Receiver Operating Characteristic Analysis for Evaluating Diagnostic Test and Predictive Models", *Circulation*, 115(5): 654-657, 2015.
- [17] H. Hafid, "Penerapan K-Fold Cross Validation untuk Menganalisis Kinerja Algoritma K-Nearest Neighbors pada Data Kasus Covid-19 di Indonesia", *Journal of Mathematics, Computations and Statistics*, Vol. 6, No. 2, Oktober 2023.
- [18] G. V. Rossum, "Python Tutorial Release 3.7.0. Python Software Foundation", 2018
- [19] A. M. Sequeira, D. Lousa, M. Rocha, "ProPythia : A Python Package for Protein Classification Base On Machine and Deep Learning", *Neurocomputing*, Vol. 484, page 172-182, 2022.
- [20] J. S. Coelho, M. R. Machado, A. A. Sousa, "PyMLDA : A Python Open Source Code for Machine Learning Damage Assessment" *Software Impactsm* 19 (2024) 100628, 2024.