

IMPLEMENTASI ALGORITMA NAIVE BAYES UNTUK MEMPREDIKSI FREKUENSI TUNAI PADA MESIN ATM DI MASA TRANSISI PEMBATASAN SOSIAL BERSKALA BESAR (PSBB) PANDEMI COVID-19

Saptari Wijaya Mulia¹, Sujiharno², Arief Wibowo³

^{1,2,3}Magister Ilmu Komputer, Universitas Budiluhur,
Jl. Ciledug Raya, Petukangan Utara, Jakarta Selatan, 12260, DKI Jakarta, Indonesia

e.mailsaptari@gmail.com¹, oedjie_arrno@yahoo.co.id², arief.wibowo@budiluhur.ac.id³

Received : July, 2020

Accepted : November, 2020

Published : April, 2021

Abstract

Determining the need of money for ATM is usually different, that is one of the problems in managing money allocation of ATM. Some seasonal factors such as holidays and the implementation of transition large-scale social restrictions related to the covid-19 pandemic that can affect fluctuations in cash transactions. In this paper aims to determine the frequency of cash withdrawals at ATM since the enactment of transition large-scale social restrictions in Jakarta using the naive bayes algorithm so it can be identified which ATM require more allocation money or not. Providing the right money allocation can improve the quality of service to customers and minimize unused money in ATM. Results of analysis using a Naive Bayes algorithm to predict cash withdrawals frequencies at ATM that show a prediction accuracy up to 81%.

Keywords: Data Mining, Naive Bayes, ATM, Social Restrictions, Covid-19.

Abstrak

Menentukan kebutuhan uang di mesin ATM pasti berbeda beda, itu merupakan salah satu kendala dalam manajemen alokasi keuangan ATM. Beberapa faktor musiman seperti hari raya, hari libur hingga di berlakukannya PSBB transisi terkait pandemi covid-19 yang bisa mempengaruhi fluktuasi transaksi tunai. Penelitian ini bertujuan untuk mengetahui frekuensi penarikan uang tunai ATM sejak diberlakukannya PSSB transisi di wilayah DKI Jakarta dengan menggunakan algoritma naive bayes sehingga dapat di ketahui ATM mana saja yang membutuhkan alokasi uang lebih ataupun sebaliknya. Mengatur alokasi yang tepat dapat meningkatkan mutu layanan kepada nasabah dan meminimalisir uang yang menganggur di mesin ATM. Hasil analisis menggunakan algoritma Naive Bayes untuk memprediksi frekuensi penarikan uang tunai ATM menunjukkan akurasi prediksi hingga 81%.

Keywords: Data Mining, Naive Bayes, ATM, PSBB, Covid-19.

1. PENDAHULUAN

Anjungan Tunai Mandiri (ATM) adalah perangkat yang digunakan oleh lembaga keuangan untuk mendukung layanan diruang publik atau area secara otomatis. Salah satu layanan yang ditawarkan ATM adalah pencairan uang tunai dari akun yang sesuai dengan nasabah[1]. Dalam manajemen alokasi uang ATM, salah satunya

adalah menjaga ketersediaan uang ATM. Sangat penting untuk mengatur alokasi uang pada mesin ATM, karena hal tersebut merupakan salah satu faktor penting dalam pelayanan kepada para nasabah. Tingkat kepuasan nasabah sangat bergantung pada pelayanan pengelolaan alokasi ketersediaan uang di mesin ATM, maka tujuan perbankan saat ini tidak hanya cukup mengejar

pada peningkatan mutu layanan saja melainkan pada nilai dan kepuasan nasabah itu sendiri sehingga dapat menghasilkan pengaruh yang positif terhadap minat para nasabah dalam penggunaan mesin ATM. Memperhatikan tingkat fluktuatif transaksi khususnya pada saat diberlakukannya transisi pembatasan sosial berskala besar (PSBB), dengan cara memprediksi transaksi khususnya pada transaksi tunai dapat dilakukan untuk memperkirakan jumlah alokasi uang yang dibutuhkan, serta bisa meminimalkan uang yang tidak terpakai atau menganggur di mesin ATM, yang sebenarnya uang tersebut bisa diputar kembali untuk menunjang proses bisnis. Dengan mengoptimalkan manajemen alokasi uang, dapat mengantisipasi mesin ATM yang mengalami kelebihan alokasi uang ataupun sebaliknya.

2. METODE PENELITIAN

Tahapan metode yang digunakan pada penelitian ini menggunakan referensi berdasarkan tahapan yang ada pada KDD (*Knowledge Discovery in Database*) berikut tahapan dari proses KDD:[2].

1) Seleksi Data

Tahapan paling awal pada proses KDD adalah menyeleksi himpunan data yang akan digunakan untuk menjadi acuan pada proses *data mining*.

2) Pra-pemrosesan/*Cleaning*

Pada tahap kedua proses KDD adalah dilakukannya proses penghapusan sekumpulan data, atau duplikasi data, dan juga data-data yang sifatnya tidak konsisten. Ditahap ini juga bisa diterapkan proses memperkaya data ataupun informasi yang relevan sehingga kualitas data dapat lebih meyakinkan dari tahapan sebelumnya.

3) Transformasi

Pada tahap ketiga dari proses KDD adalah mentransformasi data-data yang tidak memiliki entitas yang jelas, atau mengubah data menjadi format data yang dibutuhkan oleh algoritma *data mining*.

4) *Data Mining*

Pada tahap keempat dari proses KDD adalah melakukan proses pencarian pengetahuan dari data yang sudah di transformasikan pada tahapan sebelumnya. *Data mining* merupakan serangkaian proses untuk mencari nilai tambah dari sekumpulan data berupa pengetahuan yang selama ini belum diketahui secara manual[3].

5) *Interpretasi/Evaluasi*

Tahapan paling akhir dari proses KDD adalah Menginterpretasikan atau mengevaluasi pembentukan keluaran yang mudah dimengerti yang bersumber dari tahap sebelumnya.

Naive Bayes Classifier merupakan algoritma klasifikasi statistik yang didasarkan dari teorema bayes[4]. Teorema bayes merupakan suatu metode pengklasifikasian dengan memanfaatkan metode probabilitas serta statistik yang dikemukakan oleh seorang statistikawan Thomas Bayes. Teori ini memprediksi peluang yang mungkin terjadi dimasa yang akan datang yang bersumber dari kejadian yang pernah terjadi masa lampau. Pemanfaatan algoritma ini dalam hal klasifikasi wajib mempunyai masalah yang bisa dilihat dari sisi statistiknya.

Berikut tahapan proses *Naive Bayes Classifier* [5]:

- 1) Menghitung probabilitas total dari setiap kelas kejadian.
- 2) Menghitung probabilitas pada masing-masing variabel kelas.
- 3) Mengalikan semua variable kelas yang ada.
- 4) Membandingkan hasil antar kelas yang ada.

Persamaan rumus *Naive Bayes Classifier* [6]:

$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)} \quad (1)$$

Dimana $P(A|B)$ probabilitas A dan B terjadi sama dengan $P(B|A)$ probabilitas B dan A dikali dengan $P(A)$ probabilitas kejadian A dibagi dengan $P(B)$ probabilitas kejadian B.

Proses pengklasifikasian data memiliki dua tahapan, pertama adalah data latih yang dianalisis dengan menggunakan algoritma klasifikasi. yang kedua adalah data uji, yang digunakan untuk memperkirakan ketepatan dari aturan klasifikasi. Klasifikasi hanya dapat diaplikasikan pada data latih yang kuat dimana menganggap bahwa kelas positif telah mewakili minoritas tanpa kehilangan atribut umum[7].

3. HASIL DAN PEMBAHASAN

Pada bab ini dijelaskan seluruh tahapan-tahapan yang telah dilakukan mulai dari *data selection* hingga *Interpretation/Evaluation* yang ada pada KDD (*Knowledge Discovery in Database*).

1) *Data Selection*

Dataset yang digunakan adalah dataset PT XYZ di wilayah DKI Jakarta dengan total ATM mencapai 2403 ATM. Dari 2403 ATM tersebut diambil sebanyak 96 ATM sebagai sampel pengujian berdasarkan algoritma slovin dengan toleransi kesalahan sebesar 10%. Dan data sampel tersebut juga di integrasikan dengan data transaksi selama bulan juni tahun 2020 pada saat PSBB transisi diterapkan.

$$n = \frac{N}{1 + Ne^2} \quad (2)$$

Dimana n adalah jumlah sampel, N adalah jumlah populasi dan e adalah batas toleransi kesalahan[8].

$$n = \frac{2403}{1 + 2403 * 0.01^2}$$

$$n = 96.004$$

Dataset terdiri dari atribut-atribut sebagai berikut:

Tabel 1: Data atribut

TID	Menunjukkan kode atau ID ATM
SN	Menunjukkan kode <i>serial number</i> pada mesin ATM
Kanwil	Menunjukkan kantor wilayah mesin ATM itu berada
KC SPV Code	Menunjukkan kode informasi kode kantor cabang
KC SPV	Menunjukkan informasi Kantor Cabang pengelola mesin ATM
Merk ATM	Menunjukkan informasi Merk ATM
Live Date	Menunjukkan waktu ATM pertama kali beroperasi
Vendor	Menunjukkan informasi penyedia atau distributor mesin ATM
Warranty	Menunjukkan apakah ATM masih dalam waktu garansi atau tidak
OPS Days	Menunjukkan hari ATM beroperasi
OPS Time	Menunjukkan waktu ATM beroperasi
Location	Menunjukkan lokasi ATM
Network Type	Menunjukkan tipe network yang digunakan di mesin ATM

Network Provider	Menunjukkan penyedia layanan jaringan
Downtime	Menunjukkan informasi <i>downtime</i> pada mesin ATM
Sheet	Menunjukkan jenis lembar yang ada pada mesin ATM
Cassette	Menunjukkan jumlah box kaset tempat penyimpanan uang

Dari list atribut-atribut di atas dilakukan pemilihan atribut sebagai acuan klasifikasi, atribut yang dipilih sebagai berikut **Warranty, OPS Days, OPS Time, Location, Network Type, Network Provider, Downtime, Sheet, Cassette**, dan **Frequent**.

Atribut **Frequent** didapat dari integrasi data ATM dengan data transaksi tunai pada bulan juni tahun 2020 dan dijadikan sebagai kelas atau label prediksi.

2) Pre-Processing/Cleaning

Di tahap ini membersihkan data duplikasi atau menghapus data tersebut. Data atau atribut yang tidak digunakan antara lain **TID, SN, Kanwil, KC SPV Code, KC SPV, Merk ATM, Live Date, Vendor**, karena data tersebut tidak menjadi acuan klasifikasi.

3) Transformation

Di tahap ini transformasi dilakukan pada beberapa atribut, transformasi data sebagai berikut:

Tabel 2: Transformasi atribut *OPS Time*

OPS Time	Transformasi
00:00 – 23:59	24 Jam
06:00 – 15:00	Non 24 Jam
06:00 – 21:00	
09:00 – 18:00	
09:00 – 21:00	

Transformasi atribut *OPS Time* diperoleh dari dengan melihat lamanya waktu *operation time* apakah ATM beroperasi lebih dari 24 jam atau tidak.

Tabel 3: Transformasi atribut *Location*

Location	Transformasi
Mini Market	Perbelanjaan
Mall	
Pasar	
KCP	Perkantoran
KC	
Tempat Pendidikan	Sarana Umum
Rumah Sakit	

Pembagian transformasi *Location* diperoleh dari pemberian kategori seperti Mini market menjadi Perbelanjaan, KCP menjadi perkantoran, Tempat Pendidikan menjadi Sarana Umum.

Tabel 4: Transformasi atribut *Downtime*

<i>Downtime</i>	Transformasi
>=00:00:01	Pernah
00:00:00	Tidak Pernah

Pembagian transformasi *downtime* di dapat dengan melihat apakah ada waktu *downtime* yang pernah terjadi.

4) Data Mining

Data mining merupakan proses untuk pencarian informasi didalam data dengan suatu algoritma yaitu Naive Bayes. Berikut ilustrasi satu buah record dari dataset menggunakan algoritma Naive Bayes:

Warranty : In Warranty
OPS Days : All Days
OPS Time : Non 24 Jam
Location : Perbelanjaan
Network Type : VSAT
Network Provider : Patrakom
Downtime : Tidak Pernah
Sheet : 100000
Cassette : Sedikit
Frequent : Rendah

Berdasarkan persamaan dari penerapan dengan algoritma Naive Bayes maka diperoleh hasil *likelihood* sebagai berikut:

- a. Probabilitas *Warranty*
 $P(\text{In Warranty} | \text{Tinggi}) = 0.447537473$
 $P(\text{Out Warranty} | \text{Tinggi}) = 0.552462527$
 $P(\text{In Warranty} | \text{Rendah}) = 0.468345813$
 $P(\text{Out Warranty} | \text{Rendah}) = 0.531654187$
- b. Probabilitas *OPS Days*
 $P(\text{Weekdays} | \text{Tinggi}) = 0.068522484$
 $P(\text{All Days} | \text{Tinggi}) = 0.931477516$
 $P(\text{All Days} | \text{Rendah}) = 0.918992512$
 $P(\text{Weekdays} | \text{Rendah}) = 0.081007488$
- c. Probabilitas *OPS Time*
 $P(24 \text{ Jam} | \text{Tinggi}) = 0.250535332$
 $P(\text{NON 24 Jam} | \text{Tinggi}) = 0.749464668$
 $P(24 \text{ Jam} | \text{Rendah}) = 0.265486726$
 $P(\text{NON 24 Jam} | \text{Rendah}) = 0.734513274$
- d. Probabilitas *Location*
 $P(\text{Perbelanjaan} | \text{Tinggi}) = 0.512847966$
 $P(\text{Perkantoran} | \text{Tinggi}) = 0.32012848$

- $$P(\text{Sarana Umum} | \text{Tinggi}) = 0.167023555$$
- $$P(\text{Perbelanjaan} | \text{Rendah}) = 0.482641253$$
- $$P(\text{Perkantoran} | \text{Rendah}) = 0.331518039$$
- $$P(\text{Sarana Umum} | \text{Rendah}) = 0.185840708$$

- e. Probabilitas *Network Type*
 $P(\text{BRISAT} | \text{Tinggi}) = 0.37366167$
 $P(\text{Cellular} | \text{Tinggi}) = 0.027837259$
 $P(\text{MPLS} | \text{Tinggi}) = 0.468950749$
 $P(\text{VSAT} | \text{Tinggi}) = 0.129550$
 $P(\text{BRISAT} | \text{Rendah}) = 0.383934649$
 $P(\text{Cellular} | \text{Rendah}) = 0.042886317$
 $P(\text{MPLS} | \text{Rendah}) = 0.450646698$
 $P(\text{VSAT} | \text{Rendah}) = 0.122532335$
- f. Probabilitas *Network Provider*
 $P(\text{Ptrakom} | \text{Tinggi}) = 0.178800857$
 $P(\text{Telkom} | \text{Tinggi}) = 0.445396146$
 $P(\text{Telkomsel} | \text{Tinggi}) = 0.370450$
 $P(\text{Ptrakom} | \text{Rendah}) = 0.183798502$
 $P(\text{Telkom} | \text{Rendah}) = 0.449285228$
 $P(\text{Telkomsel} | \text{Rendah}) = 0.360790$
- g. Probabilitas *Downtime*
 $P(\text{Tidak Pernah} | \text{Tinggi}) = 0.733404711$
 $P(\text{Pernah} | \text{Tinggi}) = 0.266595289$
 $P(\text{Tidak Pernah} | \text{Rendah}) = 0.754254595$
 $P(\text{Pernah} | \text{Rendah}) = 0.245745405$
- h. Probabilitas *Sheet*
 $P(\text{Pecahan 50000} | \text{Tinggi}) = 0.641327623$
 $P(\text{Pecahan 100000} | \text{Tinggi}) = 0.358672377$
 $P(\text{Pecahan 50000} | \text{Rendah}) = 0.63172226$
 $P(\text{Pecahan 100000} | \text{Rendah}) = 0.36827774$
- i. Probabilitas *Cassette*
 $P(\text{Sedikit} | \text{Tinggi}) = 0.810492505$
 $P(\text{Banyak} | \text{Tinggi}) = 0.189507495$
 $P(\text{Sedikit} | \text{Rendah}) = 0.80871341$
 $P(\text{Banyak} | \text{Rendah}) = 0.19128659$
- j. Probabilitas *Frequent*
 $P(\text{Frekuensi Tinggi}) = 0.38868$
 $P(\text{Frekuensi Rendah}) = 0.61132$

Probabilitas Tinggi:

$(\text{Tinggi} | B) = (P(B | \text{Tinggi}) * P(\text{Tinggi})) / P(B)$ (3)
 Dimana $P(\text{Tinggi} | B)$ probabilitas Tinggi terhadap B sama dengan $P(B | \text{Tinggi})$ probabilitas B terhadap Tinggi dikali dengan $P(\text{Tinggi})$ probabilitas kejadian Tinggi dibagi dengan $P(B)$ probabilitas kejadian B.

$$(\text{Tinggi} | B) = P(\text{In Warranty} | \text{Tinggi}) \times P(\text{All Days} | \text{Tinggi}) \times P(24 \text{ Jam} | \text{Tinggi}) \times P(\text{Sarana Umum} | \text{Tinggi}) \times P(\text{Cellular} | \text{Tinggi}) \times P(\text{Telkomsel} | \text{Tinggi}) \times$$

$$\begin{aligned}
& P(\text{Tidak Pernah} | \text{Tinggi}) \times \\
& P(50000 | \text{Tinggi}) \times \\
& P(\text{Sedikit} | \text{Tinggi}) \times \\
& P(\text{Tinggi} | \text{Tinggi}) \\
(\text{Tinggi} | B) &= 0.447537473 \times \\
& 0.931477516 \times \\
& 0.250535332 \times \\
& 0.167023555 \times \\
& 0.027837259 \times \\
& 0.370450 \times \\
& 0.733404711 \times \\
& 0.641327623 \times \\
& 0.810492505 \times \\
& 0.38868 \\
(\text{Tinggi} | B) &= 0.38868
\end{aligned}$$

Ptobabilitas Rendah:

$$(\text{Rendah} | B) = (P(B | \text{Rendah}) * P(\text{Rendah})) / P(B) \quad (4)$$

Dimana P(Rendah | B) probabilitas Rendah terhadap B sama dengan P(B | Rendah) probabilitas B terhadap Rendah dikali dengan P(Rendah) probabilitas kejadian Rendah dibagi dengan P(B) probabilitas kejadian B.

$$\begin{aligned}
(\text{Rendah} | B) &= P(\text{In Warranty} | \text{Rendah}) \times \\
& P(\text{All Days} | \text{Rendah}) \times \\
& P(24 \text{ Jam} | \text{Rendah}) \times \\
& P(\text{Sarana Umum} | \text{Rendah}) \times \\
& P(\text{Cellular} | \text{Rendah}) \times \\
& P(\text{Telkomse l Rendah}) \times \\
& P(\text{Tidak Pernah} | \text{Rendah}) \times \\
& P(50000 | \text{Rendah}) \times \\
& P(\text{Sedikit} | \text{Rendah}) \times \\
& P(\text{Rendah} | \text{Rendah})
\end{aligned}$$

$$\begin{aligned}
(\text{Rendah} | B) &= 0.468345813 \times \\
& 0.918992512 \times \\
& 0.265486726 \times \\
& 0.185840708 \times \\
& 0.042886317 \times \\
& 0.360790 \times \\
& 0.754254595 \times \\
& 0.63172226 \times \\
& 0.80871341. \times \\
& 0.61132
\end{aligned}$$

$$(\text{Rendah} | B) = 0.61132$$

Didapat nilai untuk masing-masing probabilitas Tinggi dan Rendah, tahap akhir adalah membandingkan kedua nilai probabilitas tersebut

$$\begin{aligned}
(\text{Tinggi} | B) &= 0.38868 \\
(\text{Rendah} | B) &= 0.61132 \\
(\text{Rendah} | B) &> (\text{Tinggi} | B)
\end{aligned}$$

Dengan demikian probabilitas Rendah lebih besar, maka hasil Analisa dengan algoritma Naive Bayes memberikan prediksi hasil terhadap frekuensi yang dimiliki adalah Rendah.

5) *Interpretation/Evaluation*

Pada tahapan ini dilakukan proses evaluasi dari hasil *data mining* untuk merubah informasi menjadi lebih mudah untuk dipahami salah satunya dengan menggunakan *confusion matrix*. *Confusion matrix* merupakan alat yang digunakan untuk menganalisa seberapa baik klasifikasi. *True Positive* dan *True Negatif* memberikan informasi Ketika klasifikasi benar, sedangkan *False Positive* dan *False Negative* memberikan informasi Ketika klasifikasi salah[9]. Dari hasil pengujian terhadap 96 data *testing* dengan komposisi sebagai berikut:

Tabel 5: *Confusion matrix*

Data Aktual	Hasil Prediksi	
	Tinggi	Rendah
Tinggi	11 (A)	7 (B)
Rendah	10 (C)	68 (D)

Dimana A adalah *true positive*, B adalah *false negative*, C adalah *false positive*, D adalah *ture negative*.

Perhitungan untuk mendapatkan akurasi, *recall* dan *Specificity* sebagai berikut:

a. Perhitugnan Akurasi

$$Akurasi = \frac{A + D}{A + B + C + D} \quad (5)$$

Dimana A adalah *true positive*, B adalah *false negative*, C adalah *false positive*, D adalah *ture negative*[10].

$$Akurasi = \frac{11 + 68}{11 + 7 + 10 + 68}$$

$$\begin{aligned}
Akurasi &= 0.82291 * 100\% \\
Akurasi &= 81\%
\end{aligned}$$

b. Perhitungan *recall*

$$Recall = \frac{A}{A + B} \quad (6)$$

$$\begin{aligned}
Recall &= 0.6111 * 100\% \\
Recall &= 61\%
\end{aligned}$$

c. Perhitungan *specificity*

$$\text{specificity} = \frac{D}{D + C} \quad (7)$$

$$\begin{aligned} \text{specificity} &= 0.8717 * 100\% \\ \text{specificity call} &= 87\% \end{aligned}$$

Pada proses perhitungan akurasi penerapan algoritma naive bayes diperoleh nilai akurasi mencapai 81% yang artinya algoritma naive bayes mampu memberikan prediksi yang relatif baik.

4. KESIMPULAN

Dari penelitian ini dapat disimpulkan bahwa pada saat diberlakukannya transisi pembatasan sosial berskala besar (PSBB) menunjukkan 7 data aktual tinggi yang diprediksi rendah, 68 data aktual rendah yang diprediksi rendah, 11 data aktual tinggi diprediksi tinggi serta 10 data aktual rendah yang diprediksi tinggi dengan hasil akurasi mencapai 81%, recall 61%, *specificity* 87%.

Adapun saran untuk pengembangan penelitian ini di masa mendatang bisa menggunakan algoritma selain naive bayes serta pengumpulan data lebih luas dan lebih bervariasi yang diharapkan bisa meningkatkan nilai akurasi dan kontribusi.

DAFTAR PUSTAKA

- [1] R. Simutis, D. Dilijonas, and L. Bastina, "Cash demand forecasting for ATM using neural networks and support vector regression algorithms," *20th Int. Conf. EURO Mini Conf. "Continuous Optim. Knowledge-Based Technol. Eur. 2008*, pp. 416–421, 2008.
- [2] D. Nofriansyah and G. W. Nurcahyo, "Algoritma Data Mining Dan Pengujian," *Algoritma Data Mining dan Pengujian*. Deepublish, Yogyakarta, pp. 1–3, 2019.
- [3] Kusnawi, "Pengantar solusi data mining," *Semin. Nas. Teknol. 2007 (SNT 2007) Yogyakarta, 24 Novemb. 2007 ISSN 1978 – 9777*, vol. 2007, no. November, pp. 1–9, 2007.
- [4] S. Budi, "Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis," *Graha Ilmu*. pp. 13–14, 2007, doi: 10.1017/CBO9781107415324.004.
- [5] A. E. P. Ali Mahmudi, Moh. Miftakhur Rokhman, "Rancang Bangun Sistem Pakar untuk Mendiagnosis Tanaman Cabai Menggunakan Metode Bayes," *J. Rekayasa Dan Manaj. Sist. Inf.*, vol. 2, no. 2, pp. 48–58, 2016.
- [6] N. A. Hutagalung, "Implementasi Metode Bayes Pada Sistem Pakar Mendiagnosa Penyakit Polio," *J. Sist. Inf. dan Komputerisasi Akuntansi*, vol. 01, no. 02, pp. 26–30, 2015.
- [7] A. Saleh, "Implementasi Metode Klasifikasi Naïve Bayes Dalam Memprediksi Besarnya Penggunaan Listrik Rumah Tangga," *Creat. Inf. Technol. J.*, vol. 2, no. 3, pp. 207–217, 2015.
- [8] N. H. Sudiby, M. S. Hasibuan, I. Darmajaya, J. Za, P. Alam, and A. Bandar, "The influence of service quality on students satisfactions at private Universities in Bandar Lampung," *Int. Conf. Inf. Technol. Bus.*, no. 9, pp. 291–295, 2015, doi: 2460-7223.
- [9] Jiawei Han and M. Kamber, "Data Mining: Concepts and Techniques Second Edition," *Morgan Kaufmann*, vol. 53, no. 9, pp. 1689–1699, 2013, doi: 10.1017/CBO9781107415324.004.
- [10] A. Shiri, "Introduction to Modern Information Retrieval (2nd edition)," *Libr. Rev.*, vol. 53, no. 9, pp. 462–463, 2004, doi: 10.1108/00242530410565256.