

Klasifikasi Data Mining untuk Prediksi Potensi Nasabah dalam Membuat Deposito Berjangka

Data Mining Classification for Predicting Customer Potential in Making Term Deposits

Nia Nuraeni

Program Studi Teknik Informatika, Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri
Jakarta

e-mail: nia.nne@nusamandiri.ac.id

Abstrak

Produk atau pelayanan yang dimiliki oleh sebuah Bank sering ditawarkan kepada para nasabah nya dengan cara menawarkan produk atau pelayanan kepada nasabah secara langsung yakni dengan cara menelpon setiap nasabah yang hendak ditawarkan produk dan pelayanannya. Proses penawaran seperti ini biasa disebut pemasaran langsung. Pada proses nya proses pemasaran seperti itu menjadi tidak efektif dan efisien karna pihak Bank menghubungi satu persatu nasabah baik yang memiliki potensi maupun tidak terhadap produk yang ditawarkan. Salah satu produk yang sering ditawarkan adalah pembukaan deposito berjangka, deposito berjangka merupakan deposito yang diterbitkan menurut jangka waktu tertentu sehingga penarikannya hanya bisa dilakukan sesuai dengan perjanjian antara nasabah dan Bank. Untuk dapat memprediksi nasabah mana yang memiliki potensi untuk membuka deposito berjangka maka digunakan pengolahan data mining algoritma klasifikasi yaitu Decision Tree, Naïve Bayes dan k-Nearest Neighbor. Penelitian ini membandingkan ketiga algoritma klasifikasi tersebut untuk memilih algoritma mana yang memiliki tingkat akurasi tertinggi dalam memprediksi potensi nasabah untuk membuka deposito berjangka, hasilnya Decision Tree menjadi algoritma klasifikasi terbaik dengan nilai akurasi 91.26% dibandingkan dengan Naïve Bayes 86.96% dan k-Nearest Neighbor sebesar 90.39%..

Kata kunci—Deposito Berjangka, Data Mining, Prediksi

Abstract

Products or services that are owned by a bank are often offered to its customers by directly offering products or services to customers, namely by calling each customer whose products and services are to be offered. This bidding process is known as direct marketing. In the process, such a marketing process becomes ineffective and inefficient because the Bank contacts one by one customers who have potential or not for the products offered. One of the products that is often offered is the opening of time deposits, time deposits are deposits that are issued according to a certain period of time so that their withdrawals can only be made according to the agreement between the customer and the Bank. To be able to predict which customers have the potential to open time deposits, classification algorithm data mining processing is used, namely Decision Tree, Naïve Bayes and k-Nearest Neighbor. This study compares the three classification algorithms to choose which algorithm has the highest level of accuracy in predicting potential customers to open time deposits, the result is that the Decision Tree is the best classification algorithm with an accuracy value of 91.26% compared to Naïve Bayes 86.96% and k-Nearest Neighbor of 90.39. %.

Keywords— Term Deposit, Data Mining, Prediction

PENDAHULUAN

Dalam kamus besar Bahasa Indonesia Investasi berarti penanaman uang atau modal pada suatu perusahaan atau proyek untuk tujuan memperoleh keuntungan [1]. Secara umum investasi dapat diartikan sebagai meluangkan atau memanfaatkan waktu, uang atau tenaga demi keuntungan atau manfaat pada masa yang akan datang. Dalam perkembangannya saat ini segala macam

Informasi Artikel:

Submitted: Maret 2021, **Accepted:** April 2021, **Published:** Mei 2021

ISSN: 2685-4902 (media online), Website: <http://jurnal.umus.ac.id/index.php/intech>

jenis investasi sudah banyak dilakukan oleh setiap masyarakat. Khususnya bagi masyarakat yang menjadi nasabah dari suatu bank, saat ini investasi dalam bentuk deposito berjangka atau pinjaman dalam bentuk deposito berjangka banyak diminati oleh masyarakat. Banyak bank-bank yang sering menawarkan nasabah-nasabah nya agar mengambil atau membuat investasi berupa deposito berjangka. Menurut undang-undang Perbankan No.10 Tahun 1998 Pasal 1: "Deposito adalah simpanan yang penarikannya hanya dapat dilakukan pada waktu tertentu berdasarkan perjanjian nasabah penyimpan dengan Bank"[2]. Sedangkan deposito berjangka merupakan deposito yang diterbitkan menurut jangka waktu tertentu [3]. berbeda dengan tabungan yang bisa diambil kapan saja, deposito hanya bisa diambil sesuai pada waktu yang ditentukan antara nasabah dengan pihak Bank.

Dalam pelaksanaannya, banyak sekali keuntungan yang bisa didapatkan saat seorang nasabah melakukan atau membuka deposito berjangka yaitu mendapatkan bunga yang cukup besar, keamanan uang terjamin, resiko yang sangat kecil, akses bunga mudah dan menjadi salah satu investasi yang menguntungkan. Hal ini lah yang membuat banyak nasabah tergiur untuk melakukannya. Dalam proses pemasaran produk deposito ini, pihak Bank melakukan promosi dengan cara menghubungi nasabah secara langsung, hal ini dikarenakan Bank memiliki informasi nasabah yang biasa digunakan dalam promo produk maupun pelayanan seperti nomor telepon dan alamat surel nasabah nya. Keberhasilan kampanye atau pemasaran secara langsung ini berbanding lurus dengan efektifitas partisipasi nasabah[4]. Hanya saja kekurangan pemasaran seperti ini tidak dapat diprediksi tingkat keberhasilannya, pihak Bank hanya menghubungi nasabah sesuai dengan data nasabah yang dimiliki tanpa mengetahui apakah nasabah tersebut berpotensi untuk membuat deposito berjangka atau tidak, tentu saja ini menjadi tidak efisien bagi pihak Bank. Tingkat keberhasilan pemasaran seperti itu bisa didapatkan oleh pihak Bank dengan pengolahan data prediksi nasabah yang berpotensi membuka deposito berjangka berdasarkan data yang sudah ada, pengolahan data seperti ini dilakukan dengan data mining, data mining memiliki kemampuan dalam menganalisis suatu data yang sangat besar[5]. Beberapa algoritma klasifikasi pada data mining yang sering digunakan antara lain, *Naïve Bayes*, *Decision Tree* dan *k-Nearest Neighbor*.

Penerapan data mining *Naïve Bayes* yang dioptimasi dengan *Particle Swarm optimization* (PSO) terbukti dapat mengoptimalkan hasil prediksi dengan terlebih dahulu melakukan pembobotan atribut dengan hasil akurasi sebesar 89.70% [6]. Pada penelitian yang diaplikasikan pada nasabah Bank Umum Bekasi penerapan algoritma C4.5 merupakan algoritma yang cocok diterapkan untuk memprediksi nasabah yang berpotensi membuka deposito berjangka, dimana sebelumnya penelitian tersebut dibandingkan dengan penerapan algoritma *Naïve Bayes* dengan hasil akurasi sebesar 91.95%. [7]. Pada penelitian selanjutnya dengan menggunakan data repositori *UCI Bank Marketing* dengan jumlah atribut 17, hasil akurasi tertinggi dihasilkan oleh algoritma *Decision Tree* dengan hasil akurasi sebesar 88.48% [8]. Berdasarkan penelitian-penelitian tersebut maka dapat ditentukan bahwa algoritma data mining khususnya algoritma klasifikasi *Decision Tree*, *k-Nearest Neighbor* dan *Naïve Bayes* banyak digunakan untuk menentukan prediksi potensi nasabah yang akan membuka deposito berjangka pada suatu Bank.

METODE PENELITIAN

Metode penelitian yang penulis gunakan yaitu metode penerapan algoritma klasifikasi data mining yang terdiri dari *Decision Tree* (C4.5), *Naïve Bayes* dan *k-Nearest Neighbor*. Ketiga metode tersebut penulis bandingkan dengan menggunakan software aplikasi Rapid Miner 9.8.

Data Mining

Data mining merupakan bagian dari tahapan proses *Knowledge Discovery in Database* (KDD). Dengan data mining, kita dapat melakukan proses klasifikasi, prediksi, perkiraan dan

mendapatkan informasi lain yang bermanfaat dari kumpulan data dengan jumlah besar [9]. Data mining adalah proses pencarian pola tertentu atau informasi yang menarik dalam data yang sudah dipilih dengan menggunakan teknik atau metode tertentu. teknik, metode maupun algoritma dalam data mining sangat bervariasi. Pemilihan metode atau algoritma yang tepat sangat bergantung pada tujuan dan proses *Knowledge Discovery in Database* secara keseluruhan [9]. Algoritma Naïve Bayes, k-Nearest Neighbor dan Decision Tree merupakan contoh penerapan metode klasifikasi pada data mining [10].

Pada metode penelitian ini digunakan model proses CRISP-DM(*Cross Standard Industry Process for Data Mining*) yang terdiri dari beberapa tahapan sebagai berikut [11].

1. *Bussiness Understanding*
2. *Data Understanding*
3. *Data Preparation*
4. *Modelling*
5. *Evaluation*
6. *Deployment*

Bussiness understanding

Penggunaan dataset pada penelitian ini adalah dataset yang didapatkan dari repositori UCI dengan alamat url <https://archive.ics.uci.edu/ml/datasets/Bank+Marketing> dengan jumlah record sebanyak 41188 record. Dari 41188 Record yang didapatkan dari Repository UCI, 4640 nasabah membuat deposito berjangka sedangkan sisanya sebanyak 36548 tidak membuat deposito berjangka

Data Understanding

Berdasarkan data yang telah didapatkan diketahui jumlah record sebanyak 41188 dengan 21 atribut, dimana pembagian atribut tersebut terdiri dari 20 atribut reguler dan 1 atribut spesial sebagai class/label [12].

Tabel 1. Atribut Bank marketing

Nama Atribut	Keterangan	Jenis Atribut
Age	17-98 years old	Regular Attribute
Job	type of job (categorical: 'admin.', 'blue-collar', 'entrepreneur', 'housemaid', 'management', 'retired', 'self-employed', 'services', 'student', 'technician', 'unemployed', 'unknown')	Regular Attribute
Marital	marital status (categorical: 'divorced', 'married', 'single', 'unknown'; note: 'divorced' means divorced or widowed)	Regular Attribute
Education	(categorical: 'basic.4y', 'basic.6y', 'basic.9y', 'high.school', 'illiterate', 'professional.course', 'university.degree', 'unknown')	Regular Attribute
Default	has credit in default? (categorical: 'no', 'yes', 'unknown')	Regular Attribute
Housing	has housing loan? (categorical: 'no', 'yes', 'unknown')	Regular Attribute
Loan	has personal loan? (categorical: 'no', 'yes', 'unknown')	Regular Attribute
Contact	contact communication type (categorical: 'cellular', 'telephone')	Regular Attribute
Month	last contact month of year (categorical: 'jan', 'feb', 'mar', ..., 'nov', 'dec')	
day_of_week	last contact day of the week (categorical: 'mon', 'tue', 'wed', 'thu', 'fri')	Regular Attribute
Duration	last contact duration, in seconds (numeric). Important note: this attribute highly affects the output target (e.g., if duration=0 then y='no'). Yet, the duration is not known before a call is performed. Also, after the end of the call y is obviously known. Thus, this input should only be included for benchmark purposes and should be discarded if the intention is to have a realistic predictive model	Regular Attribute
Campaign	number of contacts performed during this campaign and for this client (numeric, includes last contact)	Regular Attribute
Pdays	number of days that passed by after the client was last contacted from a previous campaign (numeric; 999 means client was not previously contacted)	Regular Attribute
Previous	number of contacts performed before this campaign and for this client (numeric)	Regular Attribute
Poutcome	outcome of the previous marketing campaign (categorical: 'failure', 'nonexistent', 'success')	Regular Attribute
emp.var.rate	employment variation rate - quarterly indicator (numeric)	Regular Attribute
cons.price.idx	consumer price index - monthly indicator (numeric)	Regular Attribute
cons.conf.idx	consumer confidence index - monthly indicator (numeric)	Regular Attribute
euribor3m	euribor 3 month rate - daily indicator (numeric)	Regular Attribute
nr.employed	number of employees - quarterly indicator (numeric)	Regular Attribute
Y	has the client subscribed a term deposit? (binary: 'yes', 'no')	Special Attribute (label)

Sumber: [12]

Dengan record sebagai berikut.

Tabel 2. Data potensi nasabah

age	job	marital	education	default	housing	loan	contact	month	day_of_week	duration
56	housemaid	married	basic.4y	no	no	no	telephone	may	mon	261
57	services	married	high.school	unknown	no	no	telephone	may	mon	149
37	services	married	high.school	no	yes	no	telephone	may	mon	226
40	admin.	married	basic.6y	no	no	no	telephone	may	mon	151
56	services	married	high.school	no	no	yes	telephone	may	mon	307
29	unemployed	single	basic.4y	no	yes	no	cellular	nov	fri	112
73	retired	married	professional.course	no	yes	no	cellular	nov	fri	334
46	blue-collar	married	professional.course	no	no	no	cellular	nov	fri	383
56	retired	married	university.degree	no	yes	no	cellular	nov	fri	189
44	technician	married	professional.course	no	no	no	cellular	nov	fri	442
74	retired	married	professional.course	no	yes	no	cellular	nov	fri	239

campaign	pdays	previous	poutcome	emp_var_rate	cons_price_idx	cons_conf_idx	euribor3m	number_employed	y
1	999	0	nonexistent	1.1	93.994	-36.4	4.857	5191	no
1	999	0	nonexistent	1.1	93.994	-36.4	4.857	5191	no
1	999	0	nonexistent	1.1	93.994	-36.4	4.857	5191	no
1	999	0	nonexistent	1.1	93.994	-36.4	4.857	5191	no
1	999	0	nonexistent	1.1	93.994	-36.4	4.857	5191	no
1	9	1	success	-1.1	94.767	-50.8	1.028	4963.6	no
1	999	0	nonexistent	-1.1	94.767	-50.8	1.028	4963.6	yes
1	999	0	nonexistent	-1.1	94.767	-50.8	1.028	4963.6	no
2	999	0	nonexistent	-1.1	94.767	-50.8	1.028	4963.6	no
1	999	0	nonexistent	-1.1	94.767	-50.8	1.028	4963.6	yes
3	999	1	failure	-1.1	94.767	-50.8	1.028	4963.6	no

Sumber:[12].

Data Preparation

Ada beberapa tahapan pada proses Data Preparation yaitu, *data cleaning* merupakan proses pembersihan data yang memiliki nilai atau tuple yang kosong, *data integration* merupakan proses integrasi penyatuan tempat penyimpanan dan *data reduction* merupakan proses pengurangan jumlah record atau atribut yang kurang sesuai dengan label/class yang akan diprediksi atau pemilihan atribut yang tepat sesuai dengan syarat atribut penentu (label/class). Pada penelitian ini seluruh record dan atribut digunakan semuanya dengan harapan hasil yang didapatkan akan sesuai dengan data set yang telah ditentukan. Data set yang telah ditentukan dibagi menjadi Data *Training* dan Data *Testing* dengan perbandingan 90:10.

Modelling

Data preparation yang telah ditentukan akan dilakukan proses pemodelan dengan algoritma Decision Tree, Naïve Bayes dan k-Nearest Neighbor untuk menentukan pola pemodelan dengan cara memasukan data tersebut kedalam tools rapidminer, untuk mengetahui pola pemodelan tersebut digunakan data training dari data set yang telah ditentukan. Pembagian data training dan testing dilakukan otomatis menggunakan split data pada rapidminer dengan perbandingan 0.9:0.1.

Evaluation

Setelah mengetahui pola pemodelan dari setiap algoritma maka ditentukan nilai akurasi. Nilai akurasi ditentukan dari data testing dengan mengaplikasikan *tools apply model* dan *performance*. Tahap evaluasi disebut juga dengan tahap klasifikasi dikarenakan pada tahapan ini dilakukan pengujian nilai akurasi untuk setiap model algoritma serta proses evaluasi dengan kurva ROC Curve.

Deployment

Setelah proses pemodelan dan evaluasi dengan melihat nilai akurasi maka pada tahapan ini akan ditentukan nilai akurasi tertinggi dari ketiga algoritma klasifikasi yaitu dengan membandingkan algoritma Decision Tree, Naïve Bayes dan k-Nearest Neighbor. Berdasarkan hal tersebut maka penerapan algoritma klasifikasi terbaik adalah algoritma dengan nilai akurasi tertinggi.

Decision Tree

Seperti nama algoritma nya, Decision Tree merupakan alat pendukung keputusan yang menggunakan grafik atau model seperti pohon untuk mendeskripsikan hubungan antara variable yang berbeda[10]. *Decision Tree* atau pohon keputusan dihasilkan dengan cara membagi setiap nilai dari atribut menjadi cabang dalam setiap kemungkinan. Cara kerjanya adalah dengan menelusuri dari akar sampai ke cabang hingga mencapai class suatu object ditemukan [13]. Salah satu algoritma yang dapat digunakan untuk membuat pohon keputusan adalah algoritma C4.5. Algoritma C4.5 merupakan algoritma pengembangan dari Algoritma ID3 sebelumnya yang diciptakan oleh J. Rose Quinlan [9].

Secara umum algoritma C4.5 dalam membangun pohon keputusan (*Decision Tree*) sebagai berikut[14]:

- a. Pilih atribut sebagai akar
- b. Buat cabang untuk tiap-tiap nilai
- c. Bagi *case* dalam setiap cabang

Ulangi proses dalam setiap cabang sampai semua *case* pada cabang memiliki *class* yang sama.

Naïve Bayes

Algoritma Naïve Bayes merupakan suatu bentuk klasifikasi data dengan menggunakan metode probabilitas dan statistik. Metode ini pertama kali dikenalkan oleh ilmuwan inggris Thomas Bayes, yaitu digunakan untuk memprediksi peluang yang terjadi di masa depan berdasarkan pengalaman dimasa sebelumnya sehingga dikenal dengan Teorema Bayes. Metode teorema bayes kemudian dikombinasikan dengan Naïve yang diasumsikan dengan kondisi antar atribut yang saling bebas. Algoritma Naïve Bayes dapat diartikan sebagai metode yang tidak memiliki aturan, Naïve Bayes menggunakan cabang matematika yang dikenal dengan metode probabilitas untuk mencari peluang terbesar dari kemungkinan klasifikasi dengan cara melihat frekuensi tiap klasifikasi pada data training [15].

Bentuk umum Teorema Bayes:

$$P(H|X) = \frac{p(X|H) \cdot P(H)}{P(X)} \quad (1)$$

Keterangan:

X= Data class yang belum diketahui

H= Hipotesis data X merupakan suatu class spesifik

P(H|X)= Probabilitas hipotesis H berdasarkan kondisi X (*Posteriori Probaility*)

P(H)=Probabilitas Hipotesis H(*Prior Probability*)


K-Nearest Neighbor (k-NN)

Algoritma Nearest Neighbor atau dikenal juga dengan k-NN metode algoritma non parametrik dalam data mining yang dapat digunakan untuk klasifikasi dan regresi. Dalam kedua kasus tersebut inputan terdiri dari k yang mendekati data training, outputnya tergantung pada metode yang digunakan. Biasanya, nilai keluaran untuk sample data yang diprediksi ditentukan melalui rata-rata nilai k terdekatnya. NN atau k-NN dianggap sebagai salah satu metode algoritma data mining yang paling sederhana [10].

HASIL DAN PEMBAHASAN


Decision Tree

Pada algoritma *decision tree*, record yang sudah di import ke rapid miner digunakan untuk menentukan pola pohon keputusan. Adapun hasil dari pola pohon keputusan nya sebagai berikut.



Gambar 1. Pola pohon keputusan


Setelah diketahui pola pohon keputusan berdasarkan data training, maka akan ditentukan hasil akurasi berdasarkan data testing.



accuracy: 91.26%

	true no	true yes	class precision
pred. no	3560	265	93.07%
pred. yes	95	199	67.69%
class recall	97.40%	42.89%	


Gambar 2. Hasil akurasi algoritma decision tree



Gambar 3. Kurva AUC decision tree

Naïve Bayes

Pola pemodelan pada algoritma Naïve Bayes sebagai berikut.




SimpleDistribution

Distribution model for label attribute y


Class no (0.987)
20 distributions
Class yes (0.113)
20 distributions

Gambar 4. Pola pemodelan algoritma Naive Bayes

Setelah diketahui pola pada algoritma Naïve Bayes maka dilakukan evaluasi dengan data testing dengan mengaplikasikan tools *apply model* dan *performance* dan melihat nilai akurasi dan kurva AUC nya.




Gambar 5. Hasil akurasi algoritma Naïve Bayes



Gambar 6. Kurva AUC Algoritma Naïve Bayes

K-Nearest Neighbor (k-NN)

Pola pemodelan algoritma k-Nearest Neighbor dengan aplikasi rapidminer




KNNClassification


Weighted 5-Nearest Neighbour model for classification.
The model contains 41188 examples with 20 dimensions of the following classes:
no
yes

Gambar 7. Pola klasifikasi k-NN

Berdasarkan pola tersebut didapatkan hasil klasifikasi k-NN dengan hasil sebagai berikut.



Gambar 8. Hasil akurasi algoritma k-Nearest Neighbor



Gambar 9. Kurva AUC Algoritma k-Nearest Neighbor

Berdasarkan hasil pembahasan diatas maka didapatkan perbandingan hasil akurasi dari setiap algroritma

Tabel 3. Hasil perbandingan akurasi

Algoritma	Hasil akurasi
Decision Tree	91.26%
Naïve Bayes	86.96%
k-Nearest Neighbor	90.39%

KESIMPULAN

Berdasarkan hasil penelitian prediksi potensi nasabah yang membuka deposito berjangka dengan algoritma klasifikasi Decision Tree, Naïve Bayes Dan K-Nearest Neighbor maka ditetapkan bahwa akurasi tertinggi pada algoritma klasifikasi adalah algoritma decision tree dengan hasil akurasi 91.26%, Data set yang digunakan untuk menentukan akurasi adalah data testing dengan jumlah record 4119 dan Algoritma klasifikasi yang bisa digunakan adalah *Decision Tree*, *Naïve Bayes* dan *k-Nearest Neighbor* (k-NN)

SARAN

Saran pada hasil penelitian ini sebagai berikut:

1. Pada penelitian selanjutnya bisa menggunakan data set nasabah dari indonesia, sehingga bisa akurat dan sesuai jika diterapkan di Indonesia.
2. Gunakan metode optimasi untuk lebih mengoptimalkan hasil akurasi algoritma
3. Menggunakan metode algoritma klasifikasi lainnya seperti Linear Discriminat Alaysis (LDA) dan Logistic Regression (LogR).

DAFTAR PUSTAKA

- [1] “KBBI.”
- [2] Kasmir, *Bank dan Lembaga Keuangan Lainnya*. PT. Raja Grafindo Persada, 2015.
- [3] A. Rahmawati, I. Yulianti, Y. Yuliani, N. Nurhadianto, and H. B. Novitasari, “Analisis Algoritma KNN Berbasis Feature Selection untuk Memprediksi Nasabah Pengguna Deposito Melalui Pemasaran Langsung,” *Swabumi*, vol. 8, no. 1, pp. 29–36, 2020.
- [4] T. Parlar and S. K. Acaravci, “Using Data Mining Techniques for Detecting the Important Features of the Bank Direct Marketing Data,” *Int. J. Econ. Financ. Issues*, vol. 7, no. 2, pp. 692–696, 2017.
- [5] A. D. R. Prabowo and M. Muljono, “Prediksi Nasabah Yang Berpotensi Membuka Simpanan Deposito Menggunakan Naive Bayes Berbasis Particle Swarm Optimization,” *Techno.Com*, vol. 17, no. 2, pp. 208–219, 2018.
- [6] B. Umum *et al.*, “Abstrak,” vol. 19, no. September, pp. 317–326, 2020.
- [7] W. Darmawan, “Komparasi Metode Data Mining Dalam Memprediksi Nasabah Bank yang akan Memilih Tabungan Deposito Menggunakan Algoritma Klasifikasi,” *IC-Tech*, vol. XIII, no. 1, pp. 49–55, 2018.
- [8] Y. Mardi, “Data Mining : Klasifikasi Menggunakan Algoritma C4.5,” *J. Edik Inform.*, vol. 2, no. 2, pp. 213–219, 2017.
- [9] Z. Ge, Z. Song, S. X. Ding, and B. Huang, “Data Mining and Analytics in the Process Industry: The Role of Machine Learning,” *IEEE Access*, vol. 5, pp. 20590–20616, 2017.
- [10] F. Gorunescu, *Data Mining: Concept, Models and Techniques*. Springer, 2011.
- [11] P. Moro, S. Cortez, P. Rita, “A Data-Driven Approach to Predict the Success of Bank Telemarketing,” *Decis. Support Syst.*, no. 62, pp. 22–31.
- [12] B. A. B. Ii, “Data Mining Data mining,” *Min. Massive Datasets*, vol. 2, no. January 2013, pp. 5–20, 2005.
- [13] M. Bramer, *Principles of Data Mining*. London: Springer, 2020.
- [14] M. Ramadhan and W. Hadikristanto, “Analisis Tingkat Pembelian Konsumen dengan Algoritma Apriori,” vol. 2, no. 02, 2020.