

PENERAPAN DATA MINING UNTUK MEMPREDIKSI POLA NASABAH MENGGUNAKAN ALGORITMA C4.5

Donny Maulana¹⁾, Raden Rangga Bramantya Putra²⁾

Program Studi Teknik Informatika Fakultas Teknik
Universitas Pelita Bangsa
donny.maulana@pelitabangsa.ac.id

Disetujui, 30 Desember 2019

Abstraksi

Data Mining merupakan proses analisa data dari sudut yang berbeda dan mengolahnya menjadi informasi-informasi penting yang bisa digunakan untuk meningkatkan keuntungan. Secara teknis, data mining dapat disebut juga sebagai proses untuk menemukan korelasi atau pola dari ratusan atau ribuan field. Pada data mining dapat digunakan metode decision tree untuk melakukan klasifikasi. Kredit tidak lagi menjadi hal yang asing bagi masyarakat luas, banyaknya kebutuhan membuat masyarakat mengambil kredit untuk memenuhi kebutuhan konsumtif mereka. Sering kali pembayaran kredit yang macet membuat bank kerepotan, karena semakin banyaknya nasabah yang membayar secara macet dapat berdampak buruk untuk kesehatan bank. Oleh karena itu, data nasabah dari Bank XYZ menjadi bahan acuan untuk menganalisis pola nasabah pemohon kredit. Pemohon kredit termasuk dalam kategori lancar, atau macet. Untuk mengatasi masalah tersebut, dapat digunakan metode decision tree. Sehingga penelitian ini bisa dijadikan acuan pihak Bank untuk menilai nasabah dengan record data yang ada untuk pengambilan kreditselanjutnya. Informasi yang ditampilkan berupa tingkat akurasi data nasabah lancar dan macet. Kemudian hasil akurasi dari aplikasi yang diimplementasikan akan dibandingkan dengan hasil menggunakan software rapidminer. Sehingga diperoleh akurasi dengan decision tree sebesar 95%. Dapat disimpulkan bahwa algoritma C4.5 dapat digunakan untuk melakukan klasifikasi dengan cukup baik dan dapat mengukur klasifikasi nasabah.

Kata kunci: algoritma C4.5, *data mining*, klasifikasi, *decision tree*.

Abstract

Data mining is the process of analyzing data from different angles and process them into important information that can be used to increase profits. Technically, data mining can also be called as a process of finding correlation or patterns of hundreds or thousand of field. In data mining decision tree method can be used for the classification. Credit is no longer a strange thing for the general public, many need to make people take credit to meet their consumer needs. Often jammed credit payments made bank hassles, because more and more customers who pay jams can be bad for the health of banks. Thereof, customer data from Bank XYZ become a reference for analyzing pattern of customer credit applicants. Credit applicants included in the current category, or jammed. To overcome these problems, can use decision tree method. So this research could be used as a reference for Bank to assess clients with existing data record for further credit decision. The information is displayed in the form of the accuracy of customer data smoothly and jammed. Then the accuracy of the results of application that is implemented will be compared with results using software Rapidminer. This obtained with less accuracy of decision tree by 95%. It can be concluded that the C4.5 algorithm can be used to classify fairly well and can measure customer classifications.

Keywords: algorithm C4.5, *data mining*, classification, *decision tree*.

1. Pendahuluan

Kredit bukan merupakan sesuatu yang asing lagi bagi masyarakat luas, masyarakat desa saja mengenal kredit. Banyak masyarakat mengambil kredit untuk memenuhi kebutuhan mereka, seperti, untuk membangun rumah, kebutuhan sehari-hari, modal, biaya anak sekolah, dan lain-lain. Kredit adalah kepercayaan.

PT. Bank XYZ adalah salah satu bank yang menyediakan layanan Kredit Pegawai kepada para nasabahnya. Pengajuan kredit Pegawai bisa dilakukan oleh pemohon yang telah memenuhi syarat dari pihak bank. Pemberian kredit ini masih menjadi masalah yang krusial, karena pihak bank masih sangat sulit untuk menentukan pola debitur atau pemohon yang menyebabkan kredit lancar atau macet. Banyak faktor yang menyebabkan kredit macet, diantaranya jumlah penghasilan tiap bulan dan banyaknya kebutuhan ekonomi. Pembayaran kredit yang macet membuat performa bank menjadi buruk.

Pada Bank XYZ Cabang kredit yang banyak diambil adalah kredit pegawai, di mana hanya yang berpenghasilan tetap yang diperbolehkan mengambil kredit tersebut. Syarat untuk mengajukan kredit pada Bank XYZ juga sangatlah mudah, tetapi walaupun demikian, masih ada juga nasabah yang membayar kredit secara macet. Apalagi jika nasabah tersebut tiba-tiba menghilang, tidak terlihat lagi dalam instansinya. Sedangkan untuk nasabah yang meninggal sebelum kreditnya lunas, biaya itu ditanggung oleh asuransi.

Pembayaran kredit nasabah yang macet ini dapat berdampak negatif untuk kesehatan Bank, karena apabila nilai NPL Non Performing Loan pada Bank ini mencapai 2% dapat dikatakan Bank tidak memiliki performa yang bagus atau bahkan bangkrut, karena seharusnya nilai NPL pada Bank adalah di bawah 2%. Untuk menekan nilai NPL, pihak Bank harus selektif terhadap nasabah kredit yang membayar secara macet pada kredit. Sehingga penelitian ini bisa dijadikan sebagai acuan pihak Bank untuk menilai nasabah dengan record data yang ada untuk pengambilan kredit selanjutnya.

Oleh karena itu, data nasabah dari Bank XYZ menjadi bahan acuan untuk menganalisa pola nasabah pemohon kredit. Pemohon kredit termasuk dalam kategori lancar, diperlukan perhatian khusus, kurang lancar, atau macet. Dalam kasus ini digunakan teknik data mining decision tree untuk mengklasifikasi pola nasabah dengan menggunakan pohon keputusan algoritma C4.5.

Algoritma C4.5 diperkenalkan oleh Quinlan 1996 sebagai versi perbaikan dari ID3. Dalam ID3, pada decision tree hanya bisa digunakan untuk fitur bertipe kategorikal saja nominal atau ordinal, sedangkan untuk tipe numerik interval atau rasio tidak dapat digunakan. Perbaikan yang membedakan algoritma C4.5 dari ID3 adalah dapat menangani fitur dengan tipe numerik, melakukan pemotongan decision tree, dan penurunan rule set. Algoritma C4.5 juga menggunakan kriteria gain dalam menentukan fitur yang menjadi pemecah node pada pohon yang diinduksi.

Berdasarkan pertimbangan di atas dan dorongan untuk menerapkan pengetahuan yang diperoleh, maka peneliti melakukan suatu penelitian ilmiah yang membahas tentang “penerapan data mining untuk memprediksi pola nasabah menggunakan algoritma c4.5”.

2. Tinjauan Studi

2.1. Data Mining

Data mining adalah proses yang menggunakan teknik statistik, matematika, kecerdasan buatan dan *machine learning* untuk mengekstraksi dan mengidentifikasi informasi yang bermanfaat dan pengetahuan yang terkait dari berbagai database besar. Data mining merupakan serangkaian proses untuk menggali nilai tambah dari suatu kumpulan data berupa pengetahuan yang selama ini tidak diketahui secara manual.

2.2. Algoritma C4.5

Algoritma C4.5 adalah algoritma yang sangat populer digunakan oleh banyak peneliti di dunia, hal ini dijelaskan oleh Xindong Wu dan Vipin Kumar dalam bukunya yang berjudul The Top Ten Algorithms in Data Mining. Algoritma C4.5 merupakan pengembangan dari algoritma ID3 yang diciptakan oleh J. Rose Quinlan.

3. Desain Penelitian/Metodologi

3.1. Metode Pengumpulan Data

Metode pengumpulan data yang dilakukan peneliti untuk mendapatkan data yang valid adalah sebagai berikut:

1. Metode Interview atau Wawancara

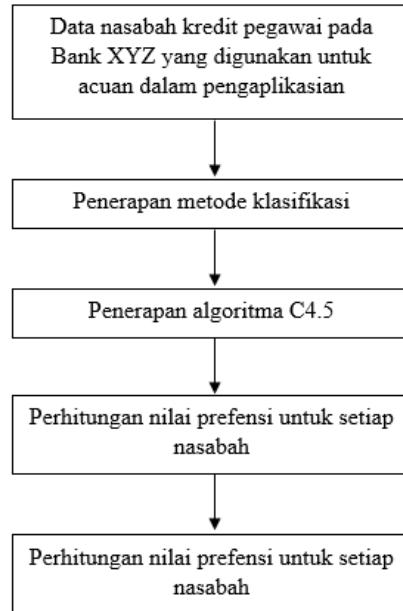
Metode wawancara dilakukan dengan melakukan wawancara terhadap pegawai Bank bagian kredit XYZ untuk mendapatkan informasi seputar syarat kredit dan kriteria kredit. Selain itu juga untuk dijadikan atribut pendukung pada penelitian ini.

2. Metode Studi Literatur

Pada metode studi literatur, peneliti mengumpulkan, membaca, mempelajari, dan mencatat literatur dari jurnal maupun buku yang berkaitan dengan algoritma C4.5. Dari metode studi literatur diharapkan dapat memberi gambaran yang dapat diimplementasikan pada aplikasi yang digunakan peneliti dalam menyelesaikan penelitian ini.

3.2. Teknik Analisa Data

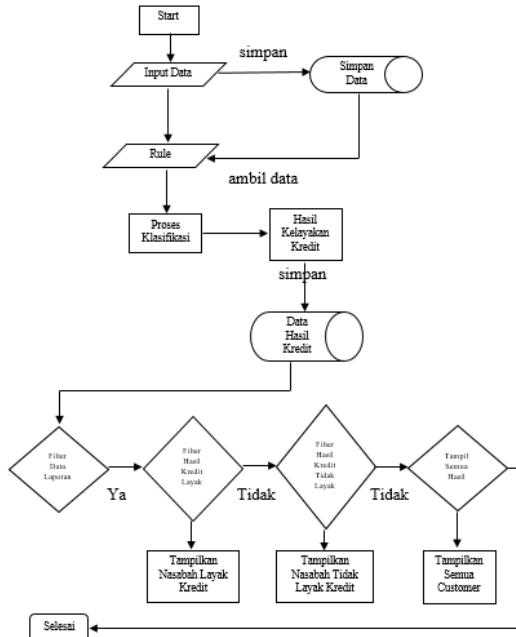
Metode yang diusulkan untuk proses seperti ini menggunakan metode klasifikasi dengan algoritma C4.5. Metode yang diusulkan untuk proses penentuan nasabah kredit adalah seperti gambar di bawah ini:



Gambar 1. Alur yang diusulkan

3.3. Metode Yang Diusulkan

Dalam penelitian ini akan dilakukan analisa menggunakan algoritma C4.5. Data dihitung dengan algoritma sesuai dengan metodenya, kemudian dicari hasil akurasinya. Dalam tahapan ini akan dilakukan beberapa langkah pengujian data yaitu seperti berikut:



Gambar 2. Flowchart Program

4. Hasil Penelitian Dan Pengujian

4.1. Pengujian Data

Pada penelitian ini digunakan 1000 data nasabah untuk menentukan akurasi klasifikasi. Terdapat 300 data nasabah yang digunakan sebagai data sample untuk perhitungan entrophy dan gain secara manual. Berikut data testing yang digunakan :

Tabel 1. Tabel Data Testing

No	Nama	No Belantara	Status Pernikahan	Rata-rata Umur	Umar	Penghasilan	Angsuran	Angka Risiko	Kode Adm
1	Vivian Andika	722101111	SELVIA HANIFAH	Caranya sendiri	45	31.000000	<=300000	12	Macet
2	Aulia Putri Vicentia	722101112	SELVIA HANIFAH	Caranya sendiri	42	44.000000	>1000000	12	Lancar
3	Akhlaki Cawalka	722101113	SELVIA HANIFAH	Caranya sendiri	24	4.000000	>800000	24	Macet
4	Ahsadiq Nujah	722101114	SELVIA HANIFAH	kecanduk	32	44.000000	>800000	24	Lancar
5	Audipin Wijaya	722101115	SELVIA HANIFAH	Caranya sendiri	34	9.000000	>1000000	24	Lancar
6	Aqil Matonduh Rizaldi	722101116	SELVIA HANIFAH	kecanduk	35	44.000000	>800000	24	Lancar
7	Aulia Putri	722101117	SELVIA HANIFAH	kecanduk	24	8.000000	>1000000	24	Lancar
8	Azizatunawati	722101118	SELVIA HANIFAH	kecanduk	34	4.000000	<=300000	24	Macet
9	Fauzia Agustina Putriwa	722101119	SELVIA HANIFAH	Caranya sendiri	43	44.000000	>800000	24	Lancar
10	Hana Afifa	722101120	SELVIA HANIFAH	kecanduk	32	4.000000	<=300000	24	Lancar
11	Haura Hanifah	722101121	SELVIA HANIFAH	Caranya sendiri	31	8.000000	<=300000	24	Macet
12	Ibnu Fazia	722101122	SELVIA HANIFAH	Caranya sendiri	46	4.000000	>1000000	12	Lancar
13	Machfudus Mekias Aisyah	722101123	SELVIA HANIFAH	Caranya sendiri	44	4.000000	>800000	24	Macet
14	Muhannad Aliq Umar	722101124	SELVIA HANIFAH	Caranya sendiri	24	3.000000	<=300000	24	Macet
15	Muhannad Fughi Ridhaika	722101125	SELVIA HANIFAH	Caranya sendiri	33	4.000000	<=300000	24	Macet
16	Natal Fahrin Dewi	722101126	SELVIA HANIFAH	kecanduk	31	47.000000	>800000	24	Lancar
17	Rafi Mulyadiq	722101127	SELVIA HANIFAH	kecanduk	28	11.000000	>1000000	24	Lancar
18	Safiyah Tuwaniyah	722101128	SELVIA HANIFAH	kecanduk	24	4.000000	<=300000	24	Macet
19	Suzann Dina Yanti	722101129	SELVIA HANIFAH	kecanduk	33	4.000000	>800000	12	Lancar
20	Sudholan Zeila Aisy	722101130	SELVIA HANIFAH	Caranya sendiri	38	4.000000	<=300000	24	Lancar
21	Siti Aisyah Afida	722101131	SELVIA HANIFAH	Caranya sendiri	48	4.000000	<=300000	24	Macet
22	Muhannad Halil Khairiyyah	722101132	SELVIA HANIFAH	kecanduk	41	4.000000	>1000000	24	Lancar
23	Nadia Khairiyah	722101133	SELVIA HANIFAH	kecanduk	25	4.000000	>800000	12	Macet
24	Zaryyah Arifia	722101134	SELVIA HANIFAH	Caranya sendiri	38	4.000000	<=300000	12	Macet
25	Ahmad Alhamzir Hadi	722101135	SELVIA HANIFAH	kecanduk	31	4.000000	<=300000	24	Macet

4.2. Pemodelan Data Mining Menggunakan Algoritma C4.5

Berikut ini merupakan langkah-langkah perhitungan nilai Entropy dan Gain pada setiap atribut yang memiliki label Lancar dan Macet :

1. Perhitungan Nilai Entropy

Langkah awal algoritma C4.5 adalah mencari nilai entropy. Pertama, tentukan terlebih dahulu nilai entrophy total dalam kasus. Rumusnya sebagai berikut :

$$\text{Entropy} = \sum -p_i \cdot \log_2 p_i \quad (4.1)$$

	Simpul	Jumlah Kasus	Kolektibilitas	
			Lancar	Macet
Total		300	156	144
Status Pernikahan				
	Belum Menikah	96	51	45
	Menikah	204	105	99
Status Rumah				
	Rumah Sendiri	198	99	99
	Kontrak	102	57	45
Umur				
	<=25	103	54	49
	>25	197	102	95
Umur				
	<=35	157	80	77
	>35	143	76	67
Umur				
	<=45	199	101	98
	>45	101	55	46
Penghasilan				
	<=3900000	111	0	111
	>3900000	189	156	33
Penghasilan				
	<=4650000	196	52	144
	>4650000	104	104	0
Angsuran				
	<=700000	144	29	115
	>=800000-1500000	92	63	29
Jangka Waktu				
	12	59	26	33
	24	130	74	56
	36	111	56	55

Maka :

Entropy Total (S)

Entropy total (101,99)

$$\begin{aligned}
 &= (-156/300) * \log_2(156/300) + (-144/300) * \log_2(144/300) \\
 &= (-0,52) * (-0,94341647163) + (-0,48) * (-1,05889368905) \\
 &= 0,49057656524 + 0,50826897074 \\
 &= 0,999
 \end{aligned}$$

Selanjutnya lakukan perhitungan entropy pada tiap atribut berdasarkan pada jumlah kasus per subset atribut, yaitu :

a. Perhitungan nilai subset pada atribut status pernikahan

Entropy Belum Menikah (51, 45)

$$\begin{aligned}
 &= (-51/96) * \log_2(51/96) + (-45/96) * \log_2(45/96) \\
 &= (-0,531) * (-0,91253715875) + (-0,469) * (-1,09310940439) \\
 &= 0,48455723129 + 0,51266831066 \\
 &= 0,997
 \end{aligned}$$

Entropy Menikah (105, 99)

$$\begin{aligned}
 &= (-105/204) * \log_2(105/204) + (-99/204) * \log_2(99/204) \\
 &= (-0,515) * (-0,9581798243) + (-0,485) * (-1,04306872189) \\
 &= 0,49346260951 + 0,50588833011 \\
 &= 0,999
 \end{aligned}$$

b. Perhitungan nilai subset pada atribut status rumah

Entropy Rumah Sendiri (99, 99)

$$\begin{aligned}
 &= (-99/198) * \log_2(99/198) + (-99/198) * \log_2(99/198) \\
 &= (-0,5) * (-1) + (-0,5) * (-1) \\
 &= 0,5 + 0,5 \\
 &= 1
 \end{aligned}$$

Entropy Kontrak (57, 45)

$$\begin{aligned}
 &= (-57/102) * \log_2(57/102) + (-45/102) * \log_2(45/102) \\
 &= (-0,559) * (-0,8395353278) + (-0,441) * (-0,896164189) \\
 &= 0,46930024824 + 0,52063236032 \\
 &= 0,99
 \end{aligned}$$

c. Perhitungan nilai subset pada atribut umur

Entropy <=25 (54, 49)

$$\begin{aligned}
 &= (-54/103) * \log_2(54/103) + (-49/103) * \log_2(49/103) \\
 &= (-0,524) * (-0,93161302502) + (-0,476) * (-1,07179068307) \\
 &= 0,48816522511 + 0,51017236514 \\
 &= 0,998
 \end{aligned}$$

Entropy >25 (102, 95)

$$\begin{aligned}
 &= (-102/197) * \log_2(42/60) + (-18/60) * \log_2(18/60) \\
 &= (-0,518) * (-0,94962647748) + (-0,482) * (-1,05219621113) \\
 &= 0,49190651533 + 0,50715857376 \\
 &= 0,999
 \end{aligned}$$

d. Perhitungan nilai subset pada atribut umur

Entropy <=35 (80, 77)

$$\begin{aligned}
 &= (-80/157) * \log_2(80/157) + (-77/157) * \log_2(77/157) \\
 &= (-0,510) * (-0,972692654) + (-0,490) * (-1,0278342082) \\
 &= 0,49607325354 + 0,50363876201 \\
 &= 1
 \end{aligned}$$

Entropy >35 (76, 67)

$$\begin{aligned}
 &= (-76/143) * \log_2(76/143) + (-67/143) * \log_2(67/143) \\
 &= (-0,531) * (-0,91194382333) + (-0,469) * (-1,09378214632) \\
 &= 0,48424217019 + 0,51298382662 \\
 &= 0,997
 \end{aligned}$$

e. Perhitungan nilai subset pada atribut umur

Entropy <=45 (101, 98)

$$\begin{aligned}
 &= (- (101/199) * \log_2 (101/199) + (- (98/199) * \log_2 (98/199)) \\
 &= (- (0,508) * (-0,97841313779) + (- (0,492) * (-1,02191477643)) \\
 &= 0,49703387399 + 0,50278207 \\
 &= 1
 \end{aligned}$$

Entropy >45 (55, 46)

$$\begin{aligned}
 &= (- (55/101) * \log_2 (55/101) + (- (46/101) * \log_2 (46/101)) \\
 &= (- (0,544) * (-0,87685176922) + (- (0,456) * (-1,13464952669)) \\
 &= 0,47700736246 + 0,51740018417 \\
 &= 0,994
 \end{aligned}$$

f. Perhitungan nilai subset pada atribut penghasilan

Entropy <=3900000 (0, 111)

$$\begin{aligned}
 &= (- (0/111) * \log_2 (0/111) + (- (111/111) * \log_2 (111/111)) \\
 &= (- (0) * (0) + (- (1) * (0))) \\
 &= 0 + 0 \\
 &= 0
 \end{aligned}$$

Entropy >3900000 (156, 33)

$$\begin{aligned}
 &= (- (156/189) * \log_2 (156/189) + (- (33/189) * \log_2 (33/189)) \\
 &= (- (0,825) * (-0,27684020535) + (- (0,175) * (-2,51784830486)) \\
 &= 0,22839316942 + 0,44062345335 \\
 &= 0,668
 \end{aligned}$$

g. Perhitungan nilai subset pada atribut penghasilan

Entropy <=4650000 (52, 144)

$$\begin{aligned}
 &= (- (52/196) * \log_2 (52/196) + (- (144/196) * \log_2 (144/196)) \\
 &= (- (0,265) * (-1,91427012597) + (- (0,735) * (-0,44478484267)) \\
 &= 0,50728158338 + 0,32691685936 \\
 &= 0,835
 \end{aligned}$$

Entropy >4650000 (104, 0) 6

$$\begin{aligned}
 &= (- (104/104) * \log_2 (104/104) + (- (0/104) * \log_2 (0/104)) \\
 &= (- (1) * (0) + (- (0) * (0))) \\
 &= 0 + 0 \\
 &= 0
 \end{aligned}$$

h. Perhitungan nilai subset pada atribut angsuran

Entropy <=700000 (29, 115)

$$\begin{aligned}
 &= (- (29/144) * \log_2 (29/144) + (- (115/144) * \log_2 (115/144)) \\
 &= (- (0,201) * (-2,31194400631) + (- (0,798) * (-0,32443495049)) \\
 &= 0,46470074526 + 0,25889909049 \\
 &= 0,725
 \end{aligned}$$

Entropy >=800000-1500000 (63, 29)

$$\begin{aligned}
 &= (- (63/92) * \log_2 (63/92) + (- (29/92) * \log_2 (29/92)) \\
 &= (- (0,685) * (-0,54628203255) + (- (0,315) * (-1,66558096093)) \\
 &= 0,3742031923 + 0,52465800269 \\
 &= 0,899
 \end{aligned}$$

Entropy >1500000 (64, 0)

$$\begin{aligned}
 &= (- (64/64) * \log_2 (64/64) + (- (0/64) * \log_2 (0/64)) \\
 &= (- (1) * (0) + (- (0) * (0))) \\
 &= 0 + 0 \\
 &= 0
 \end{aligned}$$

i. Perhitungan nilai subset pada atribut jangka waktu

Entropy 12 (26, 33)

$$\begin{aligned}
 &= (- (26/59) * \log_2 (26/59) + (- (33/59) * \log_2 (33/59)) \\
 &= (- (0,441) * (-1,18220333122) + (- (0,559) * (-0,83824893)) \\
 &= 0,52135166906 + 0,46858115187 \\
 &= 0,99
 \end{aligned}$$

Entropy 24 (74, 56)

$$\begin{aligned}
 &= (- (74/130) * \log_2 (74/130) + (- (56/130) * \log_2 (56/130)) \\
 &= (- (0,570) * (-0,8129144474) + (- (0,430) * (-1,21501289097)) \\
 &= 0,46336123501 + 0,52245554311 \\
 &= 0,986
 \end{aligned}$$

$$\begin{aligned}
 &\text{Entropy } 36 (56, 55) \\
 &= (-56/111) * \log_2 (56/111) + (-55/111) * \log_2 (55/111) \\
 &= (-0,505) * (-0,98706094429) + (-0,495) * (-1,01305615283) \\
 &= 0,49846577686 + 0,50146279564 \\
 &= 1
 \end{aligned}$$

2. Perhitungan Nilai Gain

Setelah semua perhitungan entropy pada masing-masing subset atribut selesai, kemudian lakukan perhitungan nilai gain, dengan rumus :

$$\text{Gain } (S,A) = \text{Entropy}(S) - \sum |S_i| / |S| * \text{Entropy } (S_i) \quad (4.2)$$

a. Gain status pernikahan

$$\begin{aligned}
 &= 0,999 - (96/300 * 0,997) + (204/300 * 0,999) \\
 &= 0,999 - (0,31904) + (0,67932) \\
 &= 0,999 - 0,998 \\
 &= 0,001
 \end{aligned}$$

b. Gain status rumah

$$\begin{aligned}
 &= 0,999 - (198/300 * 1) + (102/300 * 0,99) \\
 &= 0,999 - (0,66) + (0,3366) \\
 &= 0,999 - 0,997 \\
 &= 0,002
 \end{aligned}$$

c. Gain umur

$$\begin{aligned}
 &= 0,999 - (103/300 * 0,998) + (197/300 * 0,999) \\
 &= 0,999 - (0,343) + (0,656) \\
 &= 0,999 - 0,999 \\
 &= 0
 \end{aligned}$$

d. Gain umur

$$\begin{aligned}
 &= 0,999 - (157/300 * 1) + (143/300 * 0,997) \\
 &= 0,999 - (0,523) + (0,476) \\
 &= 0,999 - 0,999 \\
 &= 0
 \end{aligned}$$

e. Gain umur

$$\begin{aligned}
 &= 0,999 - (199/300 * 1) + (101/300 * 0,994) \\
 &= 0,999 - (0,663) + (0,335) \\
 &= 0,999 - 0,998 \\
 &= 0,001
 \end{aligned}$$

f. Gain penghasilan

$$\begin{aligned}
 &= 0,999 - (111/300 * 0) + (189/300 * 0,668) \\
 &= 0,999 - (0) + (0,421) \\
 &= 0,999 - 0,421
 \end{aligned}$$

$$= 0,578$$

g. Gain Penghasilan

$$\begin{aligned}
 &= 0,999 - (196/300 * 0,835) + (104/300 * 0) \\
 &= 0,999 - (0,546) + (0) \\
 &= 0,999 - 0,546 \\
 &= 0,453
 \end{aligned}$$

h. Gain angsuran

$$\begin{aligned}
 &= 0,999 - (144/300 * 0,725) + (64/300 * 0) + (92/300 * 0,899) \\
 &= 0,999 - (0,348) + (0) + (0,276) \\
 &= 0,999 - 0,624 \\
 &= 0,375
 \end{aligned}$$

i. Gain jangka waktu

$$\begin{aligned}
 &= 0,999 - (59/300 * 0,99) + (130/300 * 0,986) + (111/300 * 1) \\
 &= 0,999 - (0,1947) + (0,4273) + (0,37) \\
 &= 0,999 - 0,9983 \\
 &= 0,0007
 \end{aligned}$$

Berikut adalah tampilan hasil hitungan entropy dan gain yang selengkapnya dalam bentuk tabel :

Tabel 4.3 Tabel Hasil Perhitungan Nilai Entropy dan Gain

Nilai gain tertinggi dijadikan node akar pertama. Untuk node akar selanjutnya, dilakukan perhitungan lagi sampai semua tupel terpenuhi.

4.3 Perancangan Proses

1. Dari hasil pengujian sistem menggunakan bahasa pemrograman php dengan metode decision tree C4.5 dengan jumlah data sebanyak 300 data record, maka menghasilkan 279 data teridentifikasi benar dan 21 data teridentifikasi salah. Untuk menentukan akurasi kinerja dari sistem ini maka nilai hasil pengujian akan dimasukkan ke dalam persamaan berikut:

a. Akurasi

Perhitungan akurasi dikalikan dengan cara membagi jumlah data yang diklasifikasi secara benar dengan total sample data testing yang diuji.

$$\begin{aligned}
 &= \text{hasil benar} \times 100\% \\
 &= 279/300 \times 100\% \\
 &= 93\%
 \end{aligned}$$

b. Precision

Nilai precision dihitung dengan cara membagi jumlah data benar yang bernilai positif (True Positive) dibagi dengan jumlah data yang bernilai positif (True Positive) dan data salah yang bernilai (False Positive).

$$\begin{aligned}
 &= \frac{\text{tp}}{\text{tp} + \text{fp}} \times 100\% \\
 &= \frac{279}{279 + 21} \times 100\% \\
 &= 93\%
 \end{aligned}$$

c. Recall

Sedangkan recall dihitung dengan cara membagi data benar yang bernilai positive (tp) dengan hasil penjumlahan dari data benar yang bernilai positif (tp) dan data salah yang bernilai negative (fn).

$$\begin{aligned}
 &= \frac{\text{tp}}{\text{tp} + \text{fn}} \times 100\% \\
 &= \frac{279}{279 + 21} \times 100\% \\
 &= 93\%
 \end{aligned}$$

2. Dari hasil pengujian menggunakan software rapidminer dengan metode decision tree C4.5 dengan jumlah data

8

sebanyak 300 data record, maka menghasilkan 291 data teridentifikasi benar dan 9 data teridentifikasi salah. Berikut adalah hasil akurasi, precision, dan recall:

a. Akurasi

Perhitungan akurasi dikalikan dengan cara membagi jumlah data yang diklasifikasi secara benar dengan total sample data testing yang diuji.

$$\begin{aligned}
 &= \text{hasil benar} \times 100\% \\
 &= 291/300 \times 100\% \\
 &= 97\%
 \end{aligned}$$

b. Precision

Nilai precision dihitung dengan cara membagi jumlah data benar yang bernilai positif (True Positive) dibagi dengan jumlah data yang bernilai positif (True Positive) dan data salah yang bernilai (False Positive).

$$\begin{aligned} &= \frac{tp + fp}{tp + fn} \times 100\% \\ &= \frac{140140 + 4}{140140 + 151} \times 100\% \\ &= 97,22\% \end{aligned}$$

c. Recall

Sedangkan recall dihitung dengan cara membagi data benar yang bernilai positive (tp) dengan hasil penjumlahan dari data benar yang bernilai positif (tp) dan data salah yang bernilai negative (fn).

$$\begin{aligned} &= \frac{tp}{tp + fn} \times 100\% \\ &= \frac{140140}{140140 + 151} \times 100\% \\ &= 48,10\% \end{aligned}$$

Dari kedua hasil percobaan diatas, menggunakan software Rapidminer dan pemrograman php dapat diambil rata-rata sebagai berikut:

$$\begin{aligned} &= \text{jumlah akurasi software} + \text{jumlah akurasi Rapidminer2} \\ &= 93\% + 97\% \\ &= 95\% \end{aligned}$$

5. Kesimpulan

Berdasarkan hasil penelitian ini maka dapat beberapa kesimpulan sebagai berikut:

1. Bahwa penerapan data mining klasifikasi pola nasabah menggunakan algoritma C4.5 pada Bank XYZ menghasilkan akurasi yang tinggi, dengan menggunakan tools Rapidminer, yaitu 95%.

Daftar Pustaka