

Klasifikasi Data Aging Tunggakan Nasabah Menggunakan Metode Decision Tree Pada ULaMM Unit Kolaka

Sarimuddin¹, Jayanti Yusmah Sari^{*1}, Muh. Mail², Muh. Ariyandhi Masalu², Reski Surya Aristika², Nurfagra²

¹Program Studi Ilmu Komputer, Universitas Sembilanbelas November Kolaka

²Program Studi Sistem Informasi, Universitas Sembilanbelas November Kolaka

¹sarimuddin85@gmail.com, ^{1*}jayanti@usn.ac.id

ABSTRACT

This study aims to classify aging of loan data using the decision tree method based on plafond, outstanding principal, and the amount of loan. The subjects in this study were the debtor of ULaMM (Unit Layanan Modal Mikro), unit of Kolaka, PT. PNM (Persero) Kendari Branch. The number of samples used is 100 data debtors. Based on the results of the research conducted, it was found that the classification analysis using the Decision Tree has an accuracy rate of 95.00%, while the classification analysis using the Gradient Boosted Tree has an accuracy level of 90.00%. From the results of the analysis that has been done, it can be concluded that for the data in this study, the classification method using the Decision Tree is better than the Gradient Boosted Tree method.

Keyword: Decision Tree, Aging Tunggakan, Klasifikasi

1. Pendahuluan

Dalam bidang peminjaman modal, data *aging* tunggakan nasabah/debitur menjadi data yang paling penting yang dapat digunakan untuk memantau dan memastikan nasabah tidak melakukan penunggakan pembayaran angsuran. Secara etimologi, *aging* adalah kata benda dari lama tersimpan atau mengering dan kata sifat dari sudah lanjut usia atau menjadi tua. Sedangkan secara terminologi, dalam bidang pembiayaan modal, *aging* berarti menentukan usia atau jangka waktu dari tunggakan nasabah [1]. Dengan demikian data *aging* tunggakan nasabah merupakan data yang memuat informasi tentang usia atau jangka waktu dari tunggakan nasabah.

ULaMM (Unit Layanan Modal Mikro) unit Kolaka adalah organisasi perusahaan yang menyalurkan pembiayaan modal bagi Usaha Mikro, Kecil, Menengah, dan Koperasi (UMKMK). ULaMM unit Kolaka berada di bawah naungan PT. PNM (Permodalan Nasional Madani) (Persero) cabang Kendari. PT. PNM (Persero) cabang Kendari memiliki MMS (*Madani Management System*) untuk melakukan pengawasan dan kendali terhadap aging tunggakan nasabah yang macet setiap bulan. Namun, kelemahan MMS (*Madani Management System*) terdapat pada data *aging* tunggakan nasabah yang bersifat global serta nominatif sehingga sulit untuk mengamati pergerakan DPD (*Due Payment Date*) angsuran nasabah [1]. Dengan demikian diperlukan analisis data *aging* tunggakan nasabah untuk untuk mengawasi nasabah (debitur) yang melakukan tunggakan pembayaran angsuran.

Analisis data *aging* tunggakan nasabah dapat dilakukan dengan menggunakan metode klasifikasi pada *data mining*. Klasifikasi merupakan suatu proses yang menemukan properti-properti yang sama pada sebuah himpunan objek di dalam sebuah basis data dan mengklasifikasikannya ke dalam kelas-kelas yang berbeda menurut model klasifikasi yang ditetapkan [2]. Dengan demikian, klasifikasi merupakan cara pengelompokan data berdasarkan ciri-ciri yang dimiliki oleh data tersebut. Dalam *data mining*, beberapa metode yang sering digunakan untuk klasifikasi di antaranya Jaringan Syaraf Tiruan [3], *Decission Tree* dan *Gradient Boosting Classifier* [4]. Namun, metode yang paling sering digunakan adalah *Decission Tree*, karena metode ini memiliki beberapa kelebihan seperti dapat menghasilkan pohon keputusan yang mudah diinterpretasikan, memiliki tingkat akurasi yang dapat diterima, efisien dalam menangani atribut bertipe diskrit dan dapat menangani atribut bertipe diskrit dan numerik [5]. Selain itu, algoritma *Decision Tree* juga menghasilkan akurasi skor lebih tinggi dibandingkan algoritma klasifikasi lain seperti *Gradient Boosting Classifier*[4].

Penelitian ini akan melakukan klasifikasi data angsuran nasabah/debitur yang macet di ULaMM unit Kolaka, PT. PNM (Persero) Cabang Kendari berdasarkan data *aging* tunggakan nasabah menggunakan metode *Decission Tree*. Hasil klasifikasi selanjutnya akan digunakan untuk menganalisis angsuran nasabah

yang macet dan jumlah nasabah sehingga diharapkan dapat membantu PT. PNM (Persero) Cabang Kendari untuk menentukan tingkat kesehatan pembiayaan modal pada ULaMM unit Kolaka. Sebagai perbandingan, akurasi hasil klasifikasi menggunakan metode *Decision Tree* akan dibandingkan dengan hasil klasifikasi menggunakan *Gradient Boosting Classifier*.

2. Metodologi Penelitian

Pada penelitian ini, klasifikasi data dilakukan sesuai dengan tahapan dalam data mining yaitu pengumpulan dataset, klasifikasi data menggunakan metode *Decision Tree*, dan analisis output pengetahuan (hasil klasifikasi) serta evaluasi akurasi dari hasil klasifikasi data [6].

2.1. Klasifikasi Tunggalan

Tunggakan bila ditinjau dari Kamus Besar Bahasa Indonesia memiliki arti angsuran yang belum dibayar. Menurut Peraturan Bank Indonesia No.14/15/PBI/2012 tentang kriteria kualitas kredit (tunggalan), tunggalan dikategorikan sebagai tunggalan lancar jika dalam durasi 0-1 hari, nasabah tidak memiliki tunggalan, dan dikategorikan sebagai tunggalan macet jika terdapat tunggalan dalam durasi >180 hari [7]. Metode yang digunakan oleh PT. PNM (Persero) Cabang Kendari, ULaMM Unit Kolaka dalam menentukan tunggalan macet atau tunggalan lancar merujuk ke Peraturan Bank Indonesia No.14/15/PBI/2012 tersebut. Sehingga, jika nasabah memiliki jumlah tunggalan dalam kurun waktu >180 hari, maka tunggalan nasabah tersebut diklasifikasikan sebagai tunggalan macet. Hal ini dapat dilihat pada contoh dataset (Gambar 1).

Adapun pada penelitian ini, untuk klasifikasi tunggalan nasabah dengan metode *Decision Tree* dan metode pembandingan (*Gradient Boosting Classifier*), digunakan seluruh atribut pada dataset *aging tunggalan nasabah* (yaitu *plafond*, baki debet, jumlah tunggalan dan lama tunggalan). Hal ini berdasarkan hasil analisis terhadap metode yang digunakan oleh PT. PNM (Persero) Cabang Kendari, ULaMM Unit Kolaka yang belum dapat digunakan untuk mengamati pergerakan DPD (*Due Payment Date*) angsuran nasabah.

2.2. Dataset

Dalam penelitian ini, dilakukan pengumpulan data dengan mengambil objek penelitian yaitu data nasabah PT. PNM (Persero) Cabang Kendari, ULaMM Unit Kolaka. Data dalam penelitian ini diperoleh secara langsung dari kantor PT. PNM (Persero) Cabang Kendari, ULaMM Unit Kolaka. Dataset *aging tunggalan nasabah* akan diklasifikasi menjadi dua kategori yaitu tunggalan macet dan tunggalan lancar. Dan atribut yang terdapat dalam dataset *aging tunggalan nasabah* yaitu:

- a. *Plafond*, batas tertinggi kredit yang disediakan.
- b. Baki debet, saldo pokok dari *plafond* pinjaman yang telah disepakati dalam perjanjian kredit dan biasanya akan berkurang jika angsuran rutin dilakukan atau sesuai jadwal pembayaran oleh debitur.
- c. Jumlah tunggalan.
- d. Lama tunggalan, yakni 181-270 hari dan ≥ 271 hari.
- e. Keterangan, tunggalan lancar atau macet.

Plafond	Baki debet	Jumlah Tunggalan	Tunggalan hari 181-270	Tunggalan hari >271	Keterangan
25,000,000	11,126,533	3,009,533	0	0	Lancar
20,000,000	9,166,250	1,482,231	0	0	Lancar
12,000,000	8,579,400	2,220,000	0	0	Lancar
25,000,000	18,776,000	1,540,251	0	0	Lancar
50,000,000	3,033,239	3,258,996	0	3258996	Macet
30,000,000	1,025,700	1,467,800	0	1467800	Macet
27,000,000	14,759,350	9,588,950	1369850	0	Macet
47,000,000	5,382,050	6,219,500	0	0	Lancar
50,000,000	38,139,500	9,555,600	0	0	Lancar
40,000,000	21,768,350	9,836,000	0	0	Lancar
50,000,000	26,518,750	18,922,550	812450	0	Macet
50,000,000	43,103,050	20,960,100	6986700	0	Macet
50,000,000	36,699,300	6,986,700	0	0	Lancar
30,000,000	12,602,900	1,811,000	0	0	Lancar
40,000,000	31,391,550	5,733,300	0	0	Lancar
40,000,000	22,089,250	4,829,300	0	0	Lancar
35,000,000	28,213,050	3,344,400	0	0	Lancar
35,000,000	28,213,050	3,344,400	0	0	Lancar
50,000,000	42,115,850	9,285,172	0	0	Lancar
30,000,000	19,172,150	1,850,000	0	0	Lancar
50,000,000	40,048,300	2,265,999	0	0	Lancar
37,000,000	26,446,750	7,017,000	0	0	Lancar
30,000,000	24,658,650	1,397,350	0	0	Lancar
30,000,000	22,531,050	5,550,000	5385300	1795100	Macet
34,500,000	34,500,000	17,951,000	0	0	Lancar
35,000,000	29,481,400	1,630,200	5271939	0	Macet

Gambar 1. Contoh data *aging tunggalan nasabah*

Adapun 150 sampel data *aging* tunggakan nasabah yang digunakan untuk mengklasifikasi nasabah yang lancar dan macet yaitu 100 sampel sebagai data uji dan 50 sampel sebagai data latih, diperoleh dari kantor PT. PNM (Persero) Cabang Kendari, Unit Kolaka. Gambar 1 adalah contoh data *aging* tunggakan nasabah yang akan digunakan dalam klasifikasi *aging* tunggakan nasabah yang lancar atau macet.

Berdasarkan data *aging* tunggakan nasabah, kemudian dilakukan pemilihan atribut dan sebagian dari data dalam atribut yang ada akan ditransformasikan untuk memudahkan proses mining dalam menentukan atribut keterangan (angsuran macet atau lancar). Adapun data *aging* tunggakan yang digunakan untuk menentukan angsuran macet atau lancar yaitu 50 sampel data *aging* tunggakan yang diambil secara acak dari data 150 data yang diperoleh. Dengan demikian diperoleh data hasil transformasi dengan tiga atribut (*plafond*, baki debet dan jumlah tunggakan) yang akan dijadikan atribut *predictor* atau atribut input, dan atribut target (keterangan), di mana atribut target tersebut menjadi *class output* untuk mengklasifikasi *aging* tunggakan nasabah yang dibedakan menjadi 2 kelas yaitu lancar dan macet. Gambar 2 berikut adalah contoh data *aging* tunggakan nasabah yang akan digunakan dalam klasifikasi *aging* tunggakan nasabah yang lancar atau macet.

Plafond	Baki debet	Jumlah Tunggakan	Keterangan
25,000,000	11,126,533	3,009,533	Lancar
20,000,000	9,166,250	1,482,231	Lancar
12,000,000	8,579,400	2,220,000	Lancar
25,000,000	18,776,000	1,540,251	Lancar
50,000,000	3,033,239	3,258,996	Macet
30,000,000	1,025,700	1,467,800	Macet
27,000,000	14,759,350	9,588,950	Macet
47,000,000	5,382,050	6,219,500	Lancar
50,000,000	38,139,500	9,555,600	Lancar
40,000,000	21,768,350	9,836,000	Lancar
50,000,000	26,518,750	18,922,550	Macet
50,000,000	43,103,050	20,960,100	Macet
50,000,000	36,699,300	6,986,700	Lancar
30,000,000	12,602,900	1,811,000	Lancar
40,000,000	31,391,550	5,733,300	Lancar
40,000,000	22,089,250	4,829,300	Lancar
35,000,000	28,213,050	3,344,400	Lancar
35,000,000	28,213,050	3,344,400	Lancar
50,000,000	42,115,850	9,285,172	Lancar
30,000,000	19,172,150	1,850,000	Lancar
50,000,000	40,048,300	2,265,999	Lancar
37,000,000	26,446,750	7,017,000	Lancar
30,000,000	24,658,650	1,397,350	Lancar
30,000,000	22,531,050	5,550,000	Macet
34,500,000	34,500,000	17,951,000	Lancar
35,000,000	29,481,400	1,630,200	Macet

Gambar 2. Contoh data hasil transformasi

2.3. Decision Tree

Decision tree adalah salah satu metode klasifikasi yang paling populer karena mudah diinterpretasikan oleh manusia [8]. *Decision tree* digunakan untuk pengenalan pola dan termasuk dalam pengenalan pola secara statistik. *Decision tree* dibentuk dari 3 tipe dari simpul, yaitu simpul *leaf* yang memuat suatu akhir atau kelas target untuk suatu pohon keputusan, simpul *root* yang merupakan titik awal dari suatu *decision tree*, dan simpul perantara yang berhubungan dengan suatu pertanyaan atau pengujian [9].

Proses dalam *decision tree* adalah mengubah bentuk data (tabel) menjadi model *tree*, mengubah model *tree* menjadi *rule*, dan menyederhanakan *rule* (*pruning*). Untuk menentukan atribut terbaik, digunakan properti statistik yang disebut *information gain*, yang mengukur seberapa handal sebuah atribut dalam memisahkan sampel latihan menurut klasifikasi targetnya. Untuk menentukan *information gain* secara tepat, dimulai dengan menentukan sebuah ukuran, dalam teori informasi disebut entropi, yang mengkarakterisasikan kemurnian/ketakh murnian dari sebuah koleksi acak dari sampel. Dengan sebuah koleksi S , yang berisi sampel positif dan negatif dari target, entropi dari S relatif terhadap klasifikasi Boolean adalah [9]:

$$Entropi(S) = -P_+ \log_2 P_+ - P_- \log_2 P_- \quad (1)$$

Keterangan:

P_+ adalah proporsi sampel positif dalam S .

P_- adalah proporsi sampel negatif dalam S .

Dalam semua perhitungan mengikutkan entropi ditentukan bahwa $0 * \log_2 0$ adalah 0.

Jika atribut target bisa memiliki c kemungkinan nilai yang berbeda, maka entropi dari S terhadap klasifikasi c ditentukan menggunakan Persamaan (2) berikut [10]:

$$Entropi(S) = \sum_{i=1}^c -p_i \log_2 p_i \tag{2}$$

dengan p_i adalah proporsi kelas I terhadap S . Dari nilai entropi kemudian dapat dihitung *information gain*, Gain (S,A) dari atribut relatif A terhadap kumpulan sampel S , menggunakan Persamaan (3) [10]:

$$Gain(S,A) = Entropi(S) - \sum_{i=1}^c \frac{|s_i|}{|s|} * Entropi(s_i) \tag{3}$$

dengan jumlah partisi atribut A sebanyak c , jumlah kasus pada partisi ke- i sebanyak $|s_i|$ dan jumlah kasus dalam S sebanyak $|s|$.

2.4. Pengukuran Performance

Untuk mengukur *performance* dari hasil klasifikasi menggunakan *Decision Tree* pada penelitian ini, digunakan acuan *confusion matrix* yang meliputi akurasi, *recall*, *precision* dan *specificity*. Akurasi (Persamaan 4) merupakan rasio prediksi benar (positif dan negatif) dengan keseluruhan data. Adapun, *precision* (Persamaan 5) merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang diprediksi positif. *Recall* (Persamaan 6) merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan data yang benar positif. Dan *specificity* merupakan kebenaran memprediksi negatif dibandingkan dengan keseluruhan data negatif [11]. Dengan demikian pada penelitian ini akan digunakan ukuran akurasi, *recall* dan *precision*, sedangkan *specificity* tidak digunakan dalam penelitian ini karena tidak sesuai dengan tujuan penelitian. Tabel 1 berikut menunjukkan confusion matrix [11]

Tabel 1. Confusion Matrix

		Nilai sebenarnya	
		Positif (1)	Negatif (0)
Nilai Prediksi	Positif (1)	True Positive (TP)	False Positive (FP)
	Negatif (0)	False Negative (FN)	True Negative (TN)

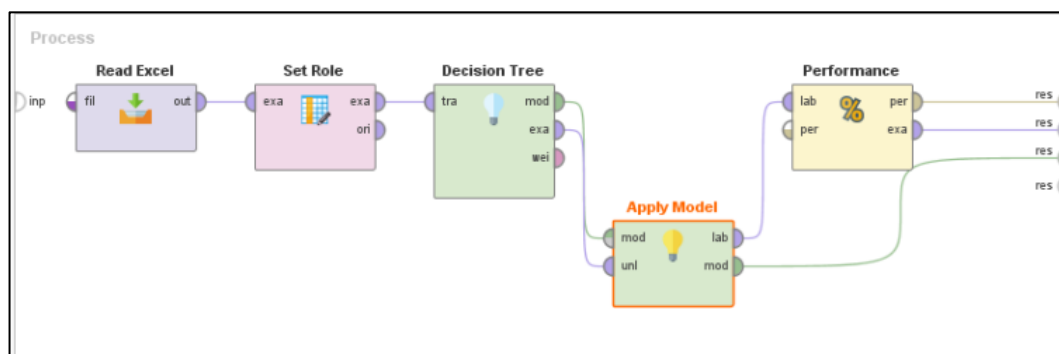
$$Akurasi = (TP + TN) / (TP+FP+FN+TN) \tag{4}$$

$$Precision = (TP) / (TP+FP) \tag{5}$$

$$Recall = (TP) / (TP + FN) \tag{6}$$

3. Analisis Hasil dan Pembahasan

Semua atribut indikator input dan atribut tujuan dalam dataset, kemudian diolah ke menggunakan *software Data Mining* yaitu RapidMiner Studio 9.4.001. Gambar 3 berikut menunjukkan desain proses *data mining* untuk klasifikasi data *aging* tunggakan nasabah menggunakan metode *decision tree* pada aplikasi RapidMiner Studio.

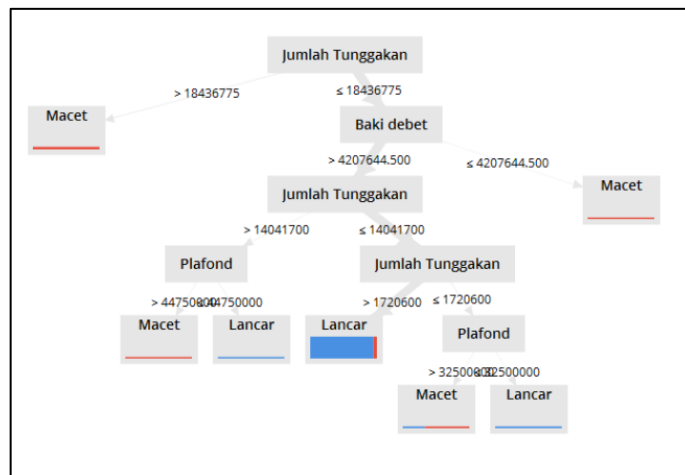


Gambar 3. Desain proses data mining

Hasil dari proses *data mining* yang ditunjukkan pada Gambar 3 adalah sebuah *decision tree* atau pohon keputusan untuk proses klasifikasi data *aging* tunggakan nasabah seperti yang dapat dilihat pada Gambar 4. Dari *decision tree* tersebut dapat dilihat bahwa atribut yang menjadi *root* adalah jumlah tunggakan, lalu diikuti oleh atribut baki debit dan *plafond* sebagai simpul perantara. Gambar 4 menunjukkan bahwa dengan metode *decision tree*, seorang nasabah diklasifikasikan sebagai nasabah dengan *aging* tunggakan macet jika:

- a. jumlah tunggakannya $> 18.436.775$, atau
- b. jumlah tunggakan $\leq 18.436.775$ dan baki debetnya $\leq 4.207.644,500$, atau
- c. jumlah tunggakan $> 18.436.775$ dan *plafond*-nya $> 44.750.000$, atau
- d. jumlah tunggakan $\leq 1.720.600$ dan *plafond*-nya $> 32.500.000$

Sedangkan nasabah yang diklasifikasikan sebagai nasabah dengan *aging* tunggakan lancar jika $18.436.775 \geq$ jumlah tunggakan $> 1.720.600$, baki debetnya $> 4.207.644,500$ dan *plafond*-nya $\leq 44.750.000$.



Gambar 4. *Decision tree* klasifikasi data *aging* tunggakan nasabah

Dengan menggunakan *decision tree* atau pohon keputusan pada Gambar 3, berikut hasil klasifikasi data *aging* tunggakan nasabah yang diperoleh:

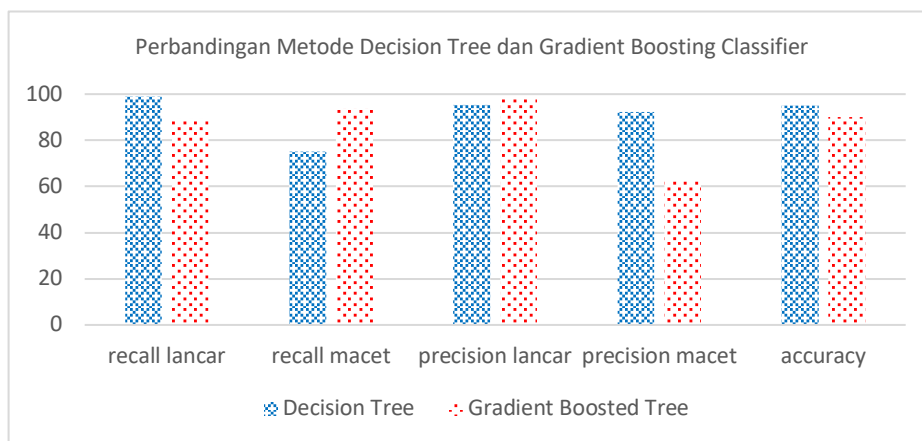
```
Jumlah Tunggakan > 18436775: Macet {Lancar=0, Macet=6}
Jumlah Tunggakan <= 18436775
| Baki debit > 4207644.500
| | Jumlah Tunggakan > 14041700
| | | Plafond > 44750000: Macet {Lancar=0, Macet=2}
| | | Plafond <= 44750000: Lancar {Lancar=2, Macet=0}
| | Jumlah Tunggakan <= 14041700
| | | Jumlah Tunggakan > 1720600: Lancar {Lancar=78, Macet=4}
| | | Jumlah Tunggakan <= 1720600
| | | | Plafond > 32500000: Macet {Lancar=1, Macet=2}
| | | | Plafond <= 32500000: Lancar {Lancar=3, Macet=0}
| Baki debit <= 4207644.500: Macet {Lancar=0, Macet=2}
```

Selanjutnya, dilakukan evaluasi dan analisis hasil klasifikasi tersebut menggunakan *confusion matrix* sehingga diperoleh nilai *recall* untuk hasil klasifikasi angsuran lancar sebesar 98,81% dan angsuran macet sebesar 75,00%. Hal ini menunjukkan jika metode *decision tree* cukup baik untuk mengklasifikasi angsuran macet sebesar 75% dari jumlah angsuran macet yang ada. Adapun untuk nilai *precision* diperoleh 95,40% untuk angsuran lancar dan 92,31% untuk angsuran macet. Hal ini menunjukkan bahwa pada semua hasil klasifikasi angsuran yang macet menggunakan metode *decision tree* terdapat 92,31% angsuran yang benar macet. Adapun hasil evaluasi ini dapat dilihat pada Tabel 2.

Tabel 2. Hasil klasifikasi menggunakan *Decision Tree*

	Lancar (true)	Macet (true)	Class precision
Klasifikasi (lancar)	83	4	95,40%
Klasifikasi (macet)	1	12	92,31%
Class recall	98,81%	75,00%	

Sebagai perbandingan, pada penelitian ini juga dilakukan klasifikasi menggunakan metode *Gradient Boosting Classifier*. Dan hasilnya akan dibandingkan dengan hasil klasifikasi sebelumnya yang menggunakan *Decision Tree*. Perbandingan hasil klasifikasi kedua metode tersebut ditunjukkan pada Gambar 5. Dari Gambar 5 tersebut, dapat dilihat bahwa hasil klasifikasi menggunakan metode *Decision Tree* memiliki nilai akurasi sebesar 95%, *recall* angsuran lancar 98,81%, *recall* angsuran macet 75,00%, *precision* angsuran lancar 95,40% dan *precision* angsuran macet 92,31%. Sedangkan metode *Gradient Boosting Classifier* memiliki nilai akurasi sebesar 90%, *recall* angsuran lancar 89,29%, *recall* angsuran macet 93,75%, *precision* angsuran lancar 98,68% dan *precision* angsuran macet 62,50%. Dengan demikian, secara umum dapat disimpulkan bahwa hasil klasifikasi menggunakan metode *Decision Tree* lebih baik dibandingkan dengan metode *Gradient Boosting Classifier*.



Gambar 5. Perbandingan hasil klasifikasi menggunakan *Decision tree* dan *Gradient Boosting Classifier*

4. Kesimpulan

Pada penelitian ini, dilakukan klasifikasi data *aging* tunggakan nasabah di ULaMM unit Kolaka, PT. PNM (Persero) Cabang Kendari untuk menentukan nasabah dengan angsuran yang macet dan tidak macet (lancar). Hasil klasifikasi menunjukkan tingkat akurasi sebesar 95%. Sebagai perbandingan, akurasi ini dibandingkan dengan hasil klasifikasi menggunakan metode *Gradient Boosting Classifier*, dan diperoleh tingkat akurasi sebesar 90%. Dengan demikian dapat disimpulkan bahwa untuk data pada penelitian ini metode *Decision Tree* lebih baik dibandingkan dengan metode *Gradient Boosting Classifier*.

References

- [1] A. H. Siregar, "Sistem Informasi Aging Tunggakan Pembiayaan Modal Mikro Dalam Pemberian Kredit Di PT. Permodalan Nasional Madani (Persero) Cabang Bandung," Doctoral Dissertation, Universitas Komputer Indonesia, 2013.
- [2] S. L. B. Ginting, W. Zarman, and I. Hamidah, "Analisis dan Penerapan Algoritma C. 45 Dalam Data Mining Untuk Memprediksi Masa Studi Mahasiswa Berdasarkan Data Nilai Akademik," in *Seminar Nasional Aplikasi Sains dan Teknologi (SNAST)*, Yogyakarta, 2014.
- [3] A. R. M. H. N. Asegaff, "Prediksi Kemacetan Angsuran Leasing Motor Menggunakan Algoritma Backpropagation Neural Network Berbasis Particle Swarm Optom," *Technol. J. Ilm.*, vol. 8, no. 4, p. 243, 2017.
- [4] K. B. Adhinata, "Implementasi Algoritma Decision Tree Classifier Untuk Klasifikasi Pelanggan Provider X Pada E-Commerce Sepulsa," Doctoral Dissertation, Universitas Ciputra, 2019.
- [5] M. Ridwan, H. Suyono, and M. Sarosa, "Penerapan Algoritma Decision Tree ID3 Untuk Prediksi Kelulusan Mahasiswa Jenjang Pendidikan D3 Di Fakultas Teknik," *J. EECCIS*, vol. 5, no. 2, pp. 1–6, 2019.
- [6] A. Sucipto, "Pada Koperasi Simpan Pinjam Dengan Menggunakan," *J. DISPROTEK*, vol. 6, no. 1, pp. 75–87, 2015.
- [7] A. Himawan, G. S. Wijaya, W. Mahmud, and Z. Arifin, "Faktor-Faktor Yang Mempengaruhi Tingkat Kolektibilitas Debitur di PT . Bank China Construction Bank Indonesia," vol. 01, no. 2, 2018.
- [8] Y. Elmande and P. Widodo, "Pemilihan Criteria Splitting dalam Algoritma Iterative Dichotomiser 3 (ID3) untuk Penentuan Kualitas Beras: Studi Kasus Pada Perum Bulog Divre Lampung," *J. Telemat. MKOM*, vol. 4, no. 1, p. 10, 2012.
- [9] A. P. Wibawa, M. Guntur, A. Purnama, M. F. Akbar, and F. A. Dwiyanto, "Metode-metode Klasifikasi," *Pros. Semin. Ilmu Komput. dan Teknol. Inf.*, vol. 3, no. 1, pp. 134–138, 2018.
- [10] M. Firmansyah and R. Aufany, "Implementasi Metode Decision Tree Dan Algoritma C4.5 Untuk Klasifikasi

- Data Nasabah Bank,” *Infokam*, vol. XII, no. 1, pp. 1–12, 2016.
- [11] B. Juba and H. S. Le, “Precision-Recall versus Accuracy and the Role of Large Data Sets,” *Proc. AAAI Conf. Artif. Intell.*, vol. 33, pp. 4039–4048, 2019.