

PERBANDINGAN METODE JARINGAN SYARAF TIRUAN DAN POHON KEPUTUSAN UNTUK PREDIKSI *CHURN*

Helena Nurramdhani Irmanda¹, Ria Astriratma², Sarika Afrizal³

^{1,2,3}Universitas Pembangunan Nasional Veteran Jakarta

Email: helenairmanda@upnvj.ac.id, astriratma@upnvj.ac.id, sarika.afrizal@upnvj.ac.id,

Abstrak

Churn merupakan suatu kecenderungan pelanggan untuk berhenti dari suatu produk atau layanan dan kemudian berpindah ke perusahaan lain. Customer churn merupakan masalah yang serius yang harus ditangani untuk keberlangsungan suatu perusahaan. Penanganan customer churn berawal dari ketepatan suatu perusahaan memprediksi customer mana yang diduga akan melakukan churn. Salah satu pendekatan dalam memprediksi customer churn adalah data mining. Penelitian ini membandingkan dua metode klasifikasi dalam data mining yaitu jaringan syaraf tiruan dan pohon keputusan untuk memprediksi customer churn pada industri perbankan. Hasil penelitian menunjukkan bahwa jaringan syaraf tiruan memiliki tingkat akurasi lebih baik dibanding pohon keputusan yaitu 86%. Selain itu jaringan syaraf tiruan juga memiliki nilai precision yang lebih baik daripada pohon keputusan, yaitu sebesar 71%. Akan tetapi untuk nilai recall, pohon keputusan memiliki nilai recall lebih baik dibanding dengan jaringan syaraf tiruan yaitu sebesar 58%.

Kata kunci: data mining, churn, jaringan syaraf tiruan, pohon keputusan

Abstract

Churn is a customer's behaviour to quit using product or service and then move to another company. Customer churn is serious problem that must be handled to keep company survive. Handling of churn customers starts from predicting which customers will churn. One approach in predicting customer churn is data mining. This study compares two classification methods in data mining namely artificial neural networks and decision trees in banking industry case. The result showed that the artificial neural network has accuracy 86% and precision 71%, which is better than the decision tree. However, the decision tree has a better recall value than the artificial neural network, which is 58%.

Keywords: data mining, churn, neural network, decision tree

1. PENDAHULUAN

Perkembangan teknologi yang pesat pada revolusi industri 4.0 yang kian mempengaruhi pola hidup masyarakat, turut menuntut bidang perbankan berinovasi agar tidak tertinggal. Terlebih lagi dunia perbankan dihadapkan dengan hadirnya pesaing dalam bidang finansial lain seperti industri *Financial* dan *Technology* (fintech) yang semakin berkembang pesat. Persaingan dalam bidang ini semakin ketat karena nasabah dapat memilih produk dan layanan yang dianggap lebih menguntungkan. Dampak dari persaingan tersebut yaitu kemungkinan nasabah berpindah ke bank maupun fintech yang lain. Dalam dunia bisnis hal ini dikenal dengan *Customer Churn* [1]. *Churn* merupakan kecenderungan pelanggan untuk berhenti menggunakan produk atau layanan dari suatu perusahaan kemudian berpindah ke perusahaan lain.

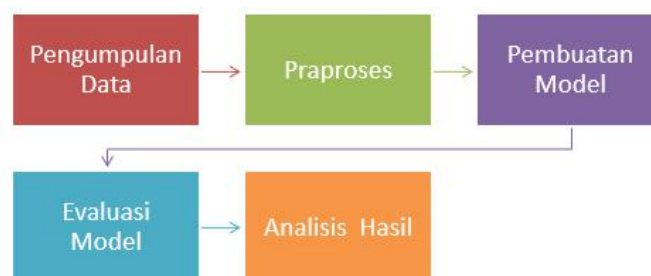
Customer churn merupakan masalah yang serius yang harus ditangani karena jika tidak dampaknya akan besar bagi suatu perusahaan. Semakin banyak *customer churn* maka dapat dikatakan ada yang salah dengan produk/layanan yang diberikan. Oleh karena itu, semakin cepat teridentifikasi maka semakin cepat pula pihak perusahaan melakukan penanganan. Strategi-strategi bisa ditentukan untuk bisa menarik kembali

nasabah yang diprediksi mempunyai kecenderungan *churn*. Salah satu pendekatan untuk memprediksi *customer churn* yaitu menggunakan pendekatan data mining.

Data mining adalah suatu proses untuk menemukan pola dan pengetahuan yang menarik dari data yang berjumlah besar [2]. Beberapa metode yang dapat digunakan dalam memprediksi di data mining yaitu: pohon keputusan, jaringan saraf tiruan, *support vector machine*, dan lain-lain. Prediksi Churn bertujuan untuk mengidentifikasi pola-pola awal dan mengenali pelanggan dengan kemungkinan churn yang tinggi. Selama beberapa tahun terakhir, terdapat minat yang meningkat untuk penelitian tentang *churn* di berbagai bidang termasuk industri perbankan, telekomunikasi, asuransi, dan lain-lain[3]. Penelitian yang telah dilakukan yaitu oleh A Sharma et al yang memprediksi *customer churn* di industri telekomunikasi selular dengan menggunakan *artificial neural network* (jaringan saraf tiruan). Hasil penelitian ini efektif memprediksi *customer churn* pada industri telekomunikasi dengan akurasi tinggi yaitu 92,35% [4]. Penelitian lain oleh Olivia et al menganalisis prediksi *churn* pada industri telekomunikasi selular menggunakan *decision tree* (pohon keputusan) mendapatkan akurasi 94,43% [5]. Dalam penelitian ini akan dibandingkan implementasi metode jaringan saraf tiruan dengan metode pohon keputusan untuk memprediksi *customer churn* pada industri perbankan.

2. METODE PENELITIAN

Pada penelitian ini dilakukan pencarian pola customer bank / nasabah yang berpotensi melakukan *churn* dan tidak *churn*. Tahapan-tahapan yang dilakukan antara lain ditunjukkan dalam Gambar 1 Diagram blok alur penelitian.



Gambar 1 diagram blok alur penelitian

Berdasarkan Gbr. 1 terdapat 4 tahapan dalam penelitian ini antara lain pengumpulan data, praproses, pembuatan model klasifikasi, evaluasi model, dan analisis hasil.

2.1. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini diperoleh dari Kaggle Datasets yaitu *Bank Customer Churn Modelling*. Dataset ini berjumlah 10000 *record* data yang terdiri dari 13 atribut dan satu atribut kelas. Atribut-atribut tersebut antara lain:

1. RowNumber: atribut yang menyatakan no urut baris data
2. CustomerID: kode unik nasabah
3. Surname: nama nasabah
4. CreditScore: reliabilitas nasabah
5. Geography: asal daerah nasabah
6. Gender: jenis kelamin nasabah, wanita atau pria

7. Age: umur nasabah
8. Tenure: Lama tahun menjadi nasabah di bank tersebut
9. Balance: sisa saldo pada rekening
10. NumberofProduct: banyaknya produk yang diambil nasabah pada bank tersebut
11. HasCrCard: status kepemilikan kartu kredit
12. IsActiveMember: status keaktifan nasabah
13. EstimatedSalary: estimasi gaji berdasarkan pemasukan
14. Exited: atribut kelas yang menyatakan churn atau tidak (1 = churn, 0 = tidak chun)

Dari 10000 *record* dataset nasabah perbankan, terdapat 2037 *record* data dengan kelas 1 (churn) dan 7963 dengan kelas 0 (tidak churn). Selanjutnya, data dipisahkan untuk *training* dan *testing*. Untuk *training* diambil 80% dari banyaknya data dan 20% digunakan untuk *testing*.

2.2. Praproses

Tahapan praproses merupakan tahap awal dari pengolahan data sebelum dilakukan permodelan. Praproses terdiri dari dua sub tahapan yaitu pemilihan atribut dan proses normalisasi data. Pemilihan atribut merupakan proses untuk memilih atribut yang signifikan dan akan digunakan pada proses pengolahan data. Proses selanjutnya yaitu proses normalisasi. Normalisasi merupakan proses transformasi dimana sebuah atribut numerik diskalakan dalam range yang lebih kecil seperti -1.0 sampai 1.0, atau 0.0 sampai 1.0 [6]. Dalam penelitian ini akan dilakukan normalisasi data dengan metode *Min-max Normalization*. Gambar 2 menunjukkan rumus *min-max normalization*.

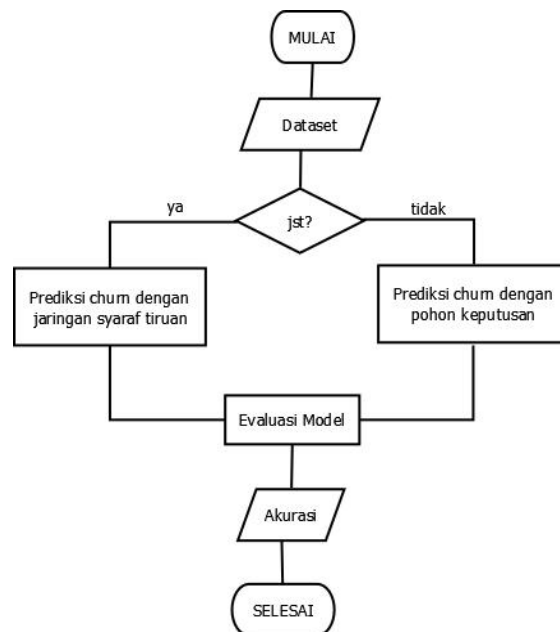
$$v' = \frac{v - \min_A}{\max_A - \min_A} (\text{new_max}_A - \text{new_min}_A) + \text{new_min}_A$$

Gambar 2 rumus *min-max normalization*

Untuk setiap fitur, nilai minimum dari fitur tersebut ditransformasikan menjadi 0, nilai maksimum ditransformasikan menjadi 1, dan setiap nilai lainnya ditransformasikan menjadi desimal antara 0 dan 1.

2.3. Pembuatan Model Klasifikasi

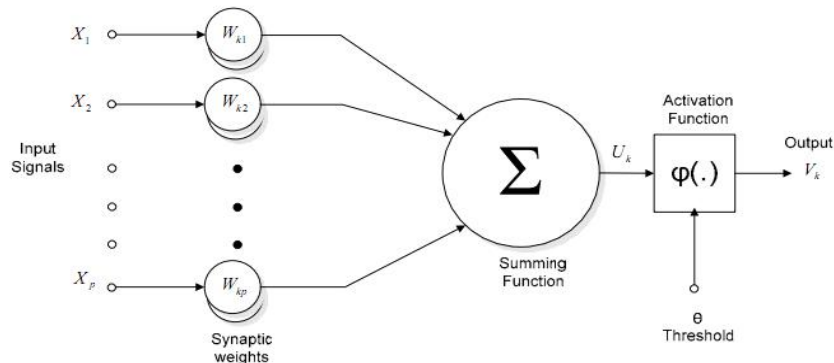
Model yang dibuat untuk prediksi churn pada penelitian ini menggunakan 2 model untuk dibandingkan yaitu jaringan saraf tiruan dan pohon keputusan. Kedua model ini akan dibandingkan untuk mengetahui kinerja mana yang lebih baik akurasi. Diagram alur proses klasifikasi ditunjukkan pada Gambar 3.



Gambar 3 flowchart proses klasifikasi

1) Jaringan Saraf Tiruan

Jaringan saraf tiruan (JST) adalah suatu model jaringan kompleks yang terdiri dari neuron (node-node) yang dikenal sebagai sel saraf. JST terinspirasi dari penelitian biologi mengenai jaringan otak manusia dan sistem saraf, JST dapat digunakan untuk menyimulasikan aktivitas saraf dalam memproses informasi di dalam otak manusia [4]. Model jaringan saraf tiruan digambarkan pada Gambar 4.



Gambar 4 Model struktur jaringan saraf tiruan [7]

Jaringan saraf tiruan terdiri atas kumpulan grup neuron yang tersusun dalam lapisan antara lain

- *Input layer*: lapisan input berfungsi sebagai penghubung jaringan ke dunia luar (sumber data).
- Lapisan tersembunyi (*hidden layer*): Suatu jaringan dapat memiliki lebih dari satu *hidden layer* atau bahkan bisa juga tidak memilikinya sama sekali.
- Lapisan *Output (output layer)*: keluaran dari neuron pada lapisan ini sudah dianggap sebagai hasil.

Proses jaringan saraf tiruan dapat dirangkum dalam 7 langkah besar antara lain:

1. Inisialisasi bobot secara acak, bobot merupakan angka kecil mendekati 0, tetapi bukan 0.
2. Masukkan input pertama di *input layer*, setiap fitur dimasukan untuk satu simpul.
3. *Forward-Propagation*: dari kiri ke kanan, neuron diaktifkan dengan cara dampak dari setiap aktivasi neuron dibatasi oleh bobot dan berjalan hingga mendapatkan bobot yang sesuai
4. Bandingkan hasil prediksi dengan hasil yang sebenarnya. Ukur eror yang dihasilkan
5. *Back-propagation*: dari kanan ke kiri. Perbarui bobot sesuai dengan seberapa besar eror yang dihasilkan dari tahap sebelumnya. Tingkat pembelajaran menentukan seberapa banyak bobot diperbaharui.
6. Ulangi langkah 1 hingga 5 dan perbarui bobot setelah setiap pengamatan.
7. Ketika seluruh pelatihan ditetapkan melewati JST, lakukan sebanyak *epoch* yang telah ditentukan.

2) Pohon Keputusan

Pohon keputusan merupakan salah satu teknik klasifikasi dengan pemodelan struktur pohon atau struktur berhirarki. Proses pembelajaran pohon keputusan memetakan tiap himpunan atribut ke satu kelas dari kelas yang didefinisikan sebelumnya[7]. Salah satu algoritma yang digunakan untuk membangun pohon keputusan yaitu ID3. Algoritma ID3 menggunakan entropy dan *information gain*. Entropy mengukur jumlah dari informasi yang ada pada atribut, sedangkan *information gain* merupakan pengurangan entropy. Secara umum algoritma ID3 untuk membangun pohon keputusan adalah sebagai berikut:

1. Menghitung *information gain* dari setiap atribut
2. Memilih atribut yang memiliki nilai *information gain* terbesar,
3. Membentuk simpul yang berisi atribut tersebut,
4. Proses perhitungan *information gain* akan terus dilaksanakan sampai semua data telah masuk ke dalam kelas yang sama.
5. Atribut yang telah dipilih tidak diikuti lagi dalam perhitungan nilai *information gain*.

2.4. Evaluasi

Proses yang dilakukan pada tahap evaluasi yaitu menghitung akurasi, *precision*, dan *recall*. Karena *churn* merupakan *binary classification* (*churn* atau tidak), maka nilai akurasi didapatkan dari hasil pembagian jumlah data uji yang benar yang terdiri dari *true positive* (TP) dan *true negative* (TN) dengan jumlah data uji keseluruhan. Gambar 5 menunjukkan rumus untuk menghitung tingkat akurasi.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$$

Gambar 5 Rumus menghitung akurasi

TP: True positive
 TN: True negative
 FP: False positive
 FN: False negative

Selain akurasi evaluasi untuk permasalahan dalam klasifikasi yang juga biasa digunakan adalah *precision*, dan *recall*. *Precision* adalah proporsi ketepatan antara informasi yang diminta dengan jawaban yang diberikan [8]. Dalam kasus ini proporsi *customer churn* yang diprediksi dengan benar (*churn*) berbanding dengan dengan jumlah keseluruhan *customer* yang diprediksi *churn* oleh model klasifikasi. Gambar 6 menunjukkan rumus untuk menghitung presisi:

$$Precision = \frac{TP}{TP + FP} \times 100\%$$

Gambar 6 Rumus menghitung precision

Recall merupakan rasio dari item relevan yang dipilih terhadap total keseluruhan item relevan yang tersedia.[8]. Dalam kasus ini proporsi pelanggan *churn* yang diprediksi benar oleh sistem berbanding dengan jumlah keseluruhan *customer churn* sebenarnya dalam data. Gambar 7 menunjukkan rumus untuk menghitung *recall*.

$$Recall = \frac{TP}{TP + FN} \times 100\%$$

Gambar 7 Rumus menghitung recall

3. HASIL DAN PEMBAHASAN

Hasil dan pembahasan merupakan uraian dari hasil penelitian beserta penjelasannya.

3.1. Praproses

Hasil dari praproses yaitu data yang sudah dipilih atributnya dan sudah dinormalisasi dengan min-max normalization. Atribut yang dipilih dari 13 atribut tersebut yaitu 11 atribut (CreditScore, Geography, Gender, Age, Tenure, Balance, NumberofProduct, HasCrCard, IsActiveMember, EstimatedSalary, dan atribut Exited sebagai kelas atribut. Untuk atribut yang memiliki nilai dengan tipe data bukan numerik, diubah menjadi numerik contohnya Geography, France diwakili dengan 1, Spain diwakili dengan 2, dan Germany diwakili dengan 3. Sedangkan untuk gender, 0 untuk Male dan 1 untuk Female.

Hasil praproses data normalisai dengan min-max normalization ditunjukkan pada Tabel 1.

Tabel 1 Data hasil praproses

CreditScore	Geography	Gender	Age	...	Exited
-------------	-----------	--------	-----	-----	--------

0.538	0	0	0.324	...	1
0.516	0.5	0	0.311	...	0
0.304	0	0	0.324	...	1
0.698	0	0	0.284	...	0
1.000	0.5	0	0.338	...	0
0.590	0.5	1	0.351	...	1
0.944	0	1	0.432	...	0
0.052	1	0	0.149	...	1
0.302	0	1	0.351	...	0
...
0.884	0	0	0.135	...	0

3.2. Evaluasi dari Model Klasifikasi

Data dibagi menjadi data uji dan data latih. Data latih yang digunakan yaitu sebanyak 80% dari jumlah dataset, 8000 *record*. Data uji yang digunakan yaitu sebanyak 20% dari jumlah data set, 2000 *record*. Proses klasifikasi dilakukan dengan dua metode yaitu metode pohon keputusan dan jaringan saraf tiruan. Parameter yang digunakan untuk pembuatan model jaringan saraf tiruan yaitu *hidden layer* sebanyak 2 dan fungsi aktivasi relu, Sedangkan proses klasifikasi dengan pohon keputusan yaitu menggunakan ID3.

Selanjutnya dilakukan proses evaluasi yang bertujuan untuk melihat nilai akurasi, presisi, dan *recall* dari proses klasifikasi yang menggunakan jaringan saraf tiruan dan pohon keputusan. Hasil dari metode jaringan saraf tiruan disajikan pada Tabel 2

Tabel 2 Confusion Matrix dengan JST

		CLASSIFIER PREDICTION	
		0	1
ACTUAL VALUE	0	1513	82
	1	202	203

Berdasarkan *confusion matrix* di Tabel 2 dapat disimpulkan bahwa terdapat 1513 customer yang tidak *churn* yang diprediksi tepat, 203 *customer churn* diprediksi tepat, 82 *customer* yang ternyata tidak *churn* yang diprediksi menjadi *churn*, dan 202 *customer* yang *churn* namun dianggap oleh *classifier* sebagai tidak *churn*. Dari *confusion matrix* tersebut dapat dihitung nilai akurasinya yaitu 86%, *precision* 71%, dan *recall* 50%. Sedangkan hasil dari metode pohon keputusan disajikan pada Tabel 3.

Tabel 3 Confusion Matrix dengan Pohon Keputusan

		CLASSIFIER PREDICTION	
		0	1
ACTUAL VALUE	0	1381	214
	1	171	234

Berdasarkan *confusion matrix* di Tabel 3 dapat disimpulkan bahwa terdapat 1381 *customer* yang tidak *churn* yang diprediksi tepat, 234 *customer churn* diprediksi tepat, 214 *customer* yang tidak *churn* yang namun diprediksi menjadi *churn*, dan 171 *customer* yang *churn* namun dianggap oleh classifier sebagai tidak *churn*. Dari *confussion matrix* tersebut dapat dihitung nilai akurasinya yaitu 81%, *precision*-nya 52%, dan nilai *recall*-nya 58%. Perbandingan nilai akurasi, *precision*, dan *recall* dideskripsikan pada Tabel 4.

Tabel 4 Evaluasi JST dan Pohon Keputusan

Hasil Evaluasi	JST	Pohon Keputusan
Akurasi	86%	81%
Precision	71%	52%
Recall	50%	58%

Berdasarkan Tabel 4, hasil akurasi dan *precision* dari model jaringan saraf tiruan lebih tinggi dibanding menggunakan pohon keputusan. Jaringan saraf tiruan memiliki persentase ketepatan lebih besar untuk memprediksi nasabah *churn* dibanding dengan pohon keputusan. Selain itu, dalam hal presisi, jaringan saraf tiruan memiliki proporsi yang lebih baik untuk memprediksi nasabah *churn* yang juga positif *churn* pada data yang sebenarnya dibanding dengan pohon keputusan.

Akan tetapi nilai *recall* dari jaringan saraf tiruan lebih kecil daripada nilai *recall* pohon keputusan. Hal ini menunjukkan bahwa model jaringan saraf tiruan dapat memisahkan nasabah yang *churn* lebih sedikit dan masih banyak *customer churn* yang lolos tidak terprediksi dibanding dengan pohon keputusan.

4. PENUTUP

Berdasarkan hasil perbandingan antara jaringan saraf tiruan dan pohon keputusan untuk memprediksi *churn* pada nasabah pelanggan dengan 10 atribut dan jumlah dataset 10000 *record* (data latih 8000 *record*, data uji 2000 *record*) dapat disimpulkan bahwa jaringan saraf tiruan memiliki tingkat akurasi lebih baik dibanding pohon keputusan yaitu 86%. Selain itu jaringan saraf tiruan juga memiliki nilai *precision* yang lebih baik daripada pohon keputusan, yaitu sebesar 71%. Akan tetapi untuk nilai *recall*, pohon keputusan memiliki nilai *recall* lebih baik dibanding dengan jaringan saraf tiruan yaitu sebesar 58%. Meskipun demikian, perbedaan nilai *recall* antara jaringan saraf tiruan dan pohon keputusan memiliki selisih yang tidak jauh, dan masih perlu ditingkatkan kembali.

Saran untuk penelitian berikutnya adalah melakukan penanganan ketidakseimbangan dataset (*imbalanced dataset*) sebelum dilakukan proses klasifikasi. Dengan demikian diharapkan nilai akurasi, presisi, dan *recall* akan meningkat.

REFERENCES

- [1] X. Yu, S. Guo, J. Guo, and X. Huang, "An extended support vector machine

- forecasting framework for customer churn in e-commerce,” *Expert Syst. Appl.*, vol. 38, no. 3, pp. 1425–1430, 2011.
- [2] J. Han, J. Pei, and M. Kamber, *Data mining: concepts and techniques*. Elsevier, 2011.
- [3] T. Vafeiadis, K. I. Diamantaras, G. Sarigiannidis, and K. C. Chatzisavvas, “A comparison of machine learning techniques for customer churn prediction,” *Simul. Model. Pract. Theory*, vol. 55, pp. 1–9, 2015.
- [4] A. Sharma, D. Panigrahi, and P. Kumar, “A neural network based approach for predicting customer churn in cellular network services,” *arXiv Prepr. arXiv1309.3945*, 2013.
- [5] C. Olivia, I. Indwiarti, and Y. Sibaroni, “Analisis prediksi churn menggunakan metode logistic regression dan algoritma decision tree,” *eProceedings Eng.*, vol. 2, no. 2, 2015.
- [6] H. Junaedi, H. Budianto, I. Maryati, and Y. Melani, “Data transformation pada data mining,” *Pros. Konf. Nas. “Inovasi dalam Desain dan Teknol. IDeaTech*, 2011.
- [7] Z. Azmi and M. Dahria, “Decision Tree Berbasis Algoritma Untuk Pengambilan Keputusan,” *J. Ilm. SAINTIKOM*, vol. 12, 2013.
- [8] P. Mayadewi and E. Rosely, “Prediksi Nilai Proyek Akhir Mahasiswa Menggunakan Algoritma Klasifikasi Data Mining,” *SESINDO 2015*, vol. 2015, 2015.