

KLASIFIKASI PEMINJAMAN NASABAH BANK MENGGUNAKAN METODE NEURAL NETWORK

Nur Hadiano¹; Hafifah Bella Novitasari²; Ami Rahmawati³

Ilmu Komputer
STMIK Nusa Mandiri Jakarta
www.nusamandiri.ac.id

¹dion.adiyanto@gmail.com; ²hafifah.bella@gmail.com; ³amirahmawati095@gmail.com

Abstract— *Payment of loans that experience difficulties in repayment or often called bad credit is a very detrimental thing for the bank, with the occurrence of bad credit the bank does not have the maximum ability to make money for investment. Choosing the right customer must go through the right analysis because the decision to approve or disagree with the loan is the main point that determines the possibility of bad credit. This study aims to classify eligible customers to obtain loans by taking into account existing parameters such as age, total income, number of families, monthly expenditure average, education level and others. This study uses a data mining classification method with a neural network model, to assess the accuracy of data processing using rapid miners then proceed with measurements using confusion matrix, ROC curve. The results of the neural network algorithm after going through confusion matrix testing, the ROC curve shows a very high accuracy value, and the dominant value of AUC and algorithm. The accuracy value is 98.24% with AUC of 0.979.*

Keywords: *Loan, Classification, Neural Network, Data Mining, Rapid Miner, Backpropagation*

Abstrak - Pembayaran pinjaman yang mengalami kesulitan dalam pengembalian atau sering disebut kredit macet merupakan sebuah hal yang sangat merugikan bagi pihak bank, dengan terjadinya kredit macet bank tidak memiliki kemampuan yang maksimal dalam melakukan perputaran uang untuk investasi. Pemilihan nasabah yang tepat harus melalui analisa yang matang karena keputusan untuk menyetujui atau tidak menyetujui pinjaman adalah poin utama yang menentukan kemungkinan terjadinya kredit macet. Penelitian ini bertujuan untuk mengklasifikasi nasabah yang layak untuk mendapatkan pinjaman dengan memperhitungkan parameter yang ada seperti usia, jumlah pendapatan, jumlah keluarga, rata-rata pengeluaran perbulan tingkat pendidikan dan lainnya. Penelitian ini menggunakan metode klasifikasi *data mining* dengan model *neural network*, untuk menilai akurasi pengolahan data

menggunakan *rapid miner* kemudian dilanjutkan dengan pengukuran menggunakan *confusion matrix*, kurva ROC. Hasil algoritma *neural network* setelah melalui pengujian *confusion matrix*, kurva ROC menunjukkan nilai akurasi yang sangat tinggi, dan nilai dominan AUC dan algoritma. Nilai akurasi adalah 98,24% dengan AUC sebesar 0,979

Kata Kunci: *Pinjaman, Klasifikasi, Neural Network, Data Mining, Rapid Miner, Backpropagation.*

PENDAHULUAN

Menurut Undang-Undang Perbankan Nomor 10 Tahun 1998, kredit adalah penyediaan uang atau tagihan yang dapat dipersamakan dengan itu berdasarkan persetujuan atau kesepakatan pinjam - meminjam antar bank dengan pihak lain yang mewajibkan pihak peminjam melunasi hutangnya setelah jangka waktu tertentu dengan pemberian bunga (Marhumi, 2017), dalam menjalankan bisnisnya penting bagi bank dan lembaga pembiayaan untuk mengevaluasi resiko kredit dilakukan dimuka bagi konsumen. Sebuah model yang baik bagi penilaian kredit akan membantu bank dan lembaga pembiayaan membuat keputusan yang tepat dalam rangka menghindari potensi besarnya resiko (Defu, Stephen, & Zhimei, 2008), Penilaian kredit sebagai teknik penilaian merupakan instrumen penting dalam industri keuangan dan perbankan (Wang, Lai, & Niu, 2011).

Besarnya jumlah kredit yang disalurkan akan menentukan keuntungan yang diperoleh. Akan tetapi tidak berarti bahwa jumlah kredit yang disalurkan besar akan memberikan keuntungan yang besar pula (Marhumi, 2017). Dewasa ini, masih banyak perusahaan keuangan atau bank mengalami kesulitan untuk meminjamkan asset berupa pinjaman (loan) kepada nasabah yang terpercaya dan sesuai ketentuan (Arun, Ishan, & Sanmeet, 2016). Dalam proses pemberian pinjaman selama ini yang dilakukan oleh bank, meskipun melalui analisa kredit yang berjenjang masih saja terdapat permasalahan yang timbul salah

satunya adalah para calon peminjam melakukan berbagai macam cara agar pinjamannya dapat disetujui oleh pihak Bank. Hal ini lah yang menyebabkan tingkat kredit macet menjadi meningkat (Iriadi & Nuraeni, 2016). Penyebab lainnya antara lain kurang akuratnya pegawai Bank dalam menganalisa calon debitur (Iriadi & Nuraeni, 2016). Salah satu metode yang dapat digunakan adalah pendekatan Machine Learning (Putri, 2018).

Data mining adalah proses menemukan korelasi, pola, dan tren baru yang bermakna dengan menyaring sejumlah besar data yang disimpan dalam repositori, menggunakan teknologi pengenalan pola serta teknik statistik dan matematik (Larose, 2005), jika *data mining* berfokus pada penggunaan program untuk membantu pembelajaran manusia terhadap data maka metode pembuatan program yang dapat belajar disebut *machine learning*, berbeda dengan program komputer yang biasa, *machine learning* adalah program yang dirancang untuk mampu belajar sendiri (Putri, 2018). Metode klasifikasi adalah salah satu metode yang paling sering digunakan, di dalam metode klasifikasi salah satu teknik yang digunakan adalah *Neural Network* yang sering digunakan untuk menyelesaikan masalah-masalah yang rumit dan berkaitan dengan identifikasi input, prediksi, pengenalan pola dan sebagainya (Windarto, 2017).

Dikarenakan hal tersebut maka dalam penelitian ini penulis akan menggunakan metode klasifikasi menggunakan teknik *Neural Network* dalam menentukan klasifikasi peminjaman bagi nasabah yang memiliki peluang tinggi untuk menjadi nasabah peminjam.

BAHAN DAN METODE

a. Sumber data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari *machine learning repository* dengan alamat web <http://www.kaggle.com> dengan jumlah data 5000 observasi mengenai perilaku nasabah pada bank dalam periode tertentu.

b. Variabel Penelitian

Dalam penelitian ini kita akan menggunakan dataset sebanyak 5000 data yang terdiri dari 14 variabel yang dapat dilihat pada Tabel 1

Tabel 1 : Variabel Penelitian

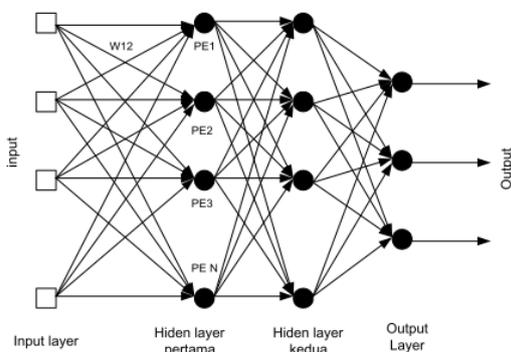
1	ID	Identitas nasabah berupa nomor urut	Kuantitatif
2	Age	Usia nasabah (tahun)	Kuantitatif
3	Experience	Pengalaman profesional	Kuantitatif
4	Income	Pendapatan per tahun nasabah (\$000)	Kuantitatif
5	ZIP Code	Kode ZIP (Zone Improvement Plan) atau kode pos alamat nasabah	Kuantitatif
6	Family	Jumlah anggota keluarga nasabah (tanpa nasabah)	Kuantitatif
7	CCAvg	Rata-rata pengeluaran nasabah menggunakan kartu kredit per bulan (\$000)	Kuantitatif
8	Education	Tingkat pendidikan nasabah 1. Belum lulus kuliah 2. Sudah lulus kuliah 3. Profesional	Kuantitatif
9	Mortgage	Harga penggadaian rumah nasabah (\$000)	Kuantitatif
10	Securities Account	Kepemilikan nasabah akan akun keamanan bersama bank 0. Tidak 1. Ya	Kuantitatif
11	CD Account	Kepemilikan nasabah akan sertifikat deposit bersama bank 0. Tidak 1. Ya	Kuantitatif
12	Online	Penggunaan nasabah akan fasilitas online banking 0. Tidak 1. Ya	Kuantitatif
13	CreditCard	Penggunaan nasabah akan kartu kredit yang dikeluarkan oleh UniversalBank 0. Tidak 1. Ya	Kuantitatif
14	Personal Loan (Target)	Pembelian peminjaman aset	Kuantitatif

(personal loan)
oleh nasabah
0. Tidak
1. Ya

Sumber : (Hadianto et al., 2019)

c. Neural Network : Multi Layer Perceptron

Neural network adalah pemrosesan informasi sistem. Secara umum neural network dapat dianggap sebagai sistem kotak hitam yang menerima input dari lingkungan dan menghasilkan output. neural network mengandung elemen pemrosesan dan pembobotan yang saling terhubung. Setiap lapisan dalam jaringan berisi oleh kelompok elemen pemrosesan seperti yang ditunjukkan pada gambar.1 (Fadly, Uddin, & Sutarto, 2002)



Sumber: (Fadly et al., 2002)
Gambar 1. Multi Layer Perceptron Neural Networks

Setiap elemen pemrosesan mengumpulkan nilai dari semua input yang terhubung ke elemen pemrosesan dan menghasilkan output melalui operasi matematika (perkalian operasi). Ada tiga lapisan yang membangun neural network, yaitu lapisan input, lapisan tersembunyi, dan lapisan keluaran. (Fadly et al., 2002)

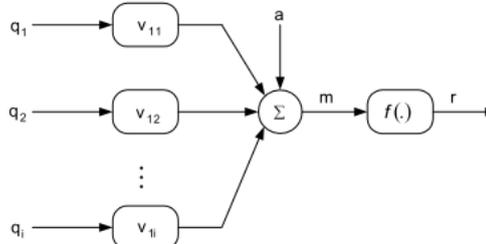
d. Artificial Neural Network

Artificial Neural Network (Jaringan Syaraf Tiruan) adalah model non-linear yang kompleks, dibangun dari komponen yang secara individu berperilaku mirip dengan model regresi. Jaringan syaraf tiruan dapat divisualisasikan dengan grafik, dan beberapa sub-grafik beberapa memiliki perilaku yang sama dengan grafik sebelumnya. Meskipun struktur dari jaringan syaraf secara eksplisit dirancang terlebih dahulu, pengolahan jaringan syaraf ini tidak untuk menghasilkan hipotesis (berbagai neuron dan pengolahan lainnya terstruktur dalam jaringan) berkembang selama proses pembelajaran. Hal ini memungkinkan neuron yang membentuk jaringan akan digunakan

sebagai pemecahan masalah dari "program itu sendiri". (Yalidhan, 2018)

e. Arsitektur Backpropagation

Algoritma back-propagation adalah algoritma yang paling populer dalam pembelajaran jaringan saraf tiruan. Algoritma ini didasarkan pada aturan pembelajaran dengan koreksi kesalahan (Fadly et al., 2002). Pembelajaran kesalahan-koreksi pada back-propagation dibagi dalam dua cara utama; pergerakan maju dan mundur. Di depan, vektor input diterapkan pada layer input di setiap jaringan kemudian mempengaruhi semua jaringan, lapis demi lapis. Output dari jaringan adalah respon dari jaringan saraf. Bobot di setiap lapisan di depan adalah tetap. Gambar dan persamaan pembelajaran maju ditunjukkan dalam gambar 2 dan persamaan 1 dan 2 (Fadly et al., 2002)



Sumber: (Fadly et al., 2002)

Gambar 2. Forward Learning Neural Network
 $m = V_q + a$ (1)
 $r = f(m)$ (2)

Pada bagian belakang semua pembobotan di setiap lapisan berubah berdasarkan aturan koreksi kesalahan. Kesalahan adalah pengurangan respons jaringan dan target keinginan. Kesalahan ini diterapkan secara mundur ke semua jaringan yang telah dilewati atau dengan cara yang berlawanan dari struktur jaringan karenanya disebut sebagai "back - propagation". Semua bobot dalam jaringan diperbaiki dan respon jaringan bergerak menuju sasaran. Teknik pembelajaran back-propagation pada koreksi error menggunakan metode gradient descent. Prinsip metode ini adalah efisiensi turunan parsial dari fungsi aktivasi di setiap elemen untuk menyesuaikan perubahan bobot pada setiap input.

$$V(k + 1) = V(k) - \eta \frac{\partial E}{\partial m} \frac{\partial m}{\partial V} \dots \dots \dots (3)$$

Dimana

$$E = \frac{1}{2} e^T(k) e(k) \dots \dots \dots (4)$$

$$e(k) = d(k) - r(k)$$

Dimana

$e(k)$ = Kesalahan antara target dan respon

$d(k)$ = Target yang diinginkan

η = Learning rate

f. Percobaan dan Pengujian Model

Dataset yang dimiliki akan dibagi 2, sebagian akan digunakan sebagai *training set* dan sebagian akan digunakan sebagai data *testing set*, kemudian data *training* tersebut akan dimasukkan dalam sebuah metode *neural network* dengan *backpropagation* program menggunakan tools *Rapid Miner*.

g. Evaluasi dan Validasi Hasil

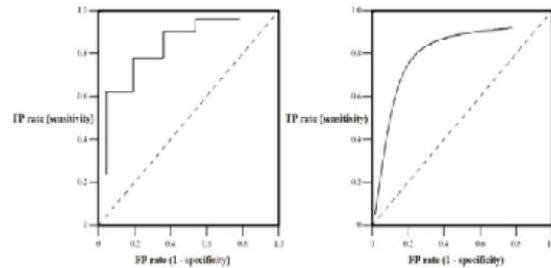
Evaluasi dan validasi dilakukan untuk membahas hasil pengamatan dan analisa yang dilakukan terhadap penelitian ini menggunakan *Neural Network* di *Rapid Miner*. Pengujian yang didapat dari metode *confusion matrix* adalah akurasi sedangkan pengujian yang didapat dari metode *ROC CURVE* (AUC) adalah gambaran kurva yang memisahkan antara kelas berbeda.

I. Cross Validation

Cross validation adalah prosedur untuk memperkirakan generalisasi kinerja dalam sebuah metode permodelan. *Cross-validation* adalah metode yang paling sering digunakan untuk evaluasi kinerja prediktif dari sebuah model, yakni model yang diberikan sebelumnya atau model yang telah dikembangkan oleh prosedur permodelan (Yadav & Shukla, 2016). Data biasanya akan dibagi menjadi dua bagian pada bagian pertama dilakukan pelatihan sementara pada bagian lainnya dilakukan uji kinerja, skema pelatihan dan pengujian bekerja dengan baik pada model klasifikasi di dalam *machine learning*, beberapa *record* dalam *dataset* dijadikan data *training* untuk dilatih sementara *record* lainnya di dalam *dataset* digunakan sebagai data *testing*, hal tersebut adalah prinsip dasar dari *cross validation*, karena hal tersebutlah *cross-validation* sangat diterima dalam komunitas *data mining* dan *machine learning* dan berfungsi sebagai prosedur standard untuk pemilihan model atau pemilihan prosedur permodelan, (Yadav & Shukla, 2016)

II. Pengukuran menggunakan ROC Curve

Pengukuran hasil validasi dengan menggunakan *ROC Curve* dan *Confusion matrix* sampai mendapatkan tingkat akurasi yang tertinggi. *ROC Curve* adalah Kurva ROC banyak digunakan para peneliti untuk menilai hasil prediksi Kurva ROC menggambarkan kinerja klasifikasi tanpa memperhatikan distribusi kelas atau kesalahan, pada sumbu *vertical* menggambarkan nilai positif (TP) dan sumbu *horizontal* menandakan nilai negative (FP). (Ir. Adi Sucipto, n.d.).. ditunjukkan dalam gambar 3



Sumber : (Sucipto, 2012)

Gambar 3. Contoh Grafik ROC

Garis diagonal yang membelah ruang ROC menggambarkan ruang diatas garis diagonal menandakan klasifikasi baik dan ruang dibawah garis diagonal menandakan klasifikasi buruk, sementara tebakan yang benar-benar acak terdapat pada sepanjang garis diagonal mulai dari kiri bawah sampai dengan kanan atas

Sebuah metode umum untuk menghitung daerah dibawah kurva ROC adalah *Area Under Curve* (AUC) dimana bidang yang berada dibawah kurva mempunyai nilai yang selalu berada pada nilai 0,0 dan 1,0. Namun yang menarik untuk dihitung adalah yang mempunyai luas diatas 0,5, semakin tinggi luasnya maka akan semakin baik seperti petunjuk yang disajikan berikut ini (Ir. Adi Sucipto, n.d.):

- 0.9- 1.00 = klasifikasi yang sangat baik
- 0.8 - 0.9 = klasifikasi baik
- 0.7 - 0.8 = klasifikasi rata-rata
- 0.6 - 0.7 = klasifikasi rendah
- 0.5 - 0.6 = kegagalan

III Pengukuran menggunakan *confusion matrix*

Pengukuran terhadap kinerja suatu sistem klasifikasi merupakan hal yang penting. Kinerja sistem klasifikasi menggambarkan seberapa baik sistem dalam mengklasifikasikan data. *Confusion matrix* merupakan salah satu metode yang dapat digunakan untuk mengukur kinerja suatu metode klasifikasi. Pada dasarnya *confusion matrix* mengandung informasi yang membandingkan hasil klasifikasi yang dilakukan oleh sistem dengan hasil klasifikasi yang seharusnya. (E. Prasetyo, 2012)

Pada pengukuran kinerja menggunakan *confusion matrix*, terdapat 4 (empat) istilah sebagai representasi hasil proses klasifikasi. Keempat istilah tersebut adalah *True Positive* (TP), *True Negative* (TN), *False Positive* (FP) dan *False Negative* (FN). Nilai *True Negative* (TN) merupakan jumlah data negatif yang terdeteksi dengan benar, sedangkan *False Positive* (FP) merupakan data negatif namun terdeteksi sebagai data positif. Sementara itu, *True Positive* (TP) merupakan data positif yang

terdeteksi benar. *False Negative*(FN) merupakan kebalikan dari *True Positive*, sehingga data positif, namun terdeteksi sebagai data negatif.

Pada jenis klasifikasi *binary* yang hanya memiliki 2 keluaran kelas, *confusion matrix* dapat disajikan seperti pada Tabel 2 (Sokolova & Lapalme, 2009)

Tabel 2. *Confusion Matrix*

Kelas	Terklasifikasi Positif	Terklasifikasi Negatif
Positif	TP (True Positive)	FN (False Negative)
Negatif	FP (False Positive)	TN (True Negative)

Sumber : (Hadianto et al., 2019)

Dari tabel diatas kita dapat melihat nilai akurasi, presisi dan *recall* didapat dari nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP) dan *False Negative* (FN), nilai akurasi menggambarkan seberapa akurat dan efektifitas sistem secara keseluruhan dalam mengklasifikasikan data secara benar, perhitungan akurasi dinyatakan dalam persamaan 5 (Sokolova & Lapalme, 2009)

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \dots\dots\dots (5)$$

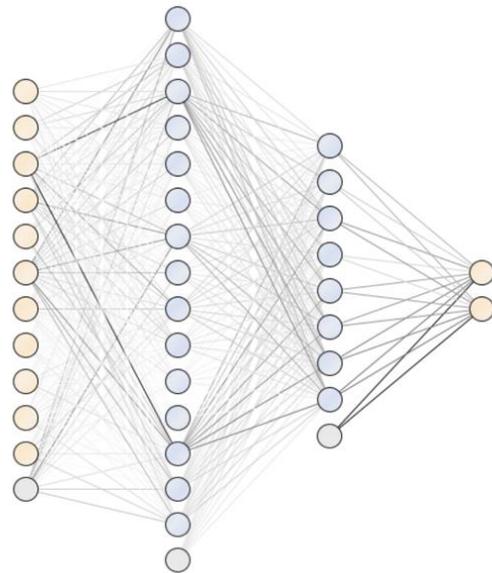
HASIL DAN PEMBAHASAN

Hasil Penelitian

Pada bagian ini akan membahas hasil implementasi penggunaan *Neural Network* pada penentuan klasifikasi peminjaman nasabah pada sebuah bank dengan menggunakan metode *backpropagation*, Analisa difokuskan pada pengaruh struktur *neural network*, tingkat pembelajaran (*learning rate*) *neural network*, dan *momentum neural network*, dalam penelitian ini menggunakan *dataset* sebanyak 5000 data.

Dalam penelitian untuk mendapatkan struktur *neural network* yang optimal kami melakukan beberapa uji coba perubahan struktur dengan tingkat pembelajaran (*learning rate*), *training cycles* dan *momentum* yang sama yakni *learning rate* = 0.0.1, *training cycles* = 500 dan *momentum* = 0.1, pertama kali kami mencoba struktur 12 – 7 – 3 – 1 artinya struktur tersebut memiliki 12 *input*, 7 *neuron* pertama yang tersembunyi, 3 *neuron* kedua yang tersembunyi dan 1 *output*, kemudian kami mencoba beberapa struktur yang lain seperti 12 – 20 – 8 – 1, 12 – 15 – 8 – 1, 12 – 10 – 5 – 1, 12 – 7 – 3 – 1, dari semua struktur yang dicoba tidak terdapat perbedaan yang signifikan hanya selisih 0 (nol) koma sekian, akan tetapi dari seluruh struktur yang sudah kami coba kami menemukan bahwa struktur 12 – 15 – 8 – 1 merupakan struktur yang paling adaptif dengan

akurasi 98.24 %, struktur 12 – 15 – 8 – 1 adalah seperti pada gambar 4. dibawah ini.



Sumber : (Hadianto et al., 2019)

Gambar 4. *Neural Network* Struktur 12 – 15 – 8 – 1

Tingkat akurasi yang didapatkan dari hasil uji coba ini adalah sebesar 98.24% +/- 0.62% dan AUC sebesar 0.979 +/- 0.0.14 seperti pada gambar yang disajikan dari *Performance Vector* seperti pada gambar 5. dibawah ini.

PerformanceVector

```
PerformanceVector:
accuracy: 98.24% +/- 0.62% (micro average: 98.24%)
ConfusionMatrix:
True:  0      1
0:    4491   59
1:      29   421
AUC: 0.979 +/- 0.014 (micro average: 0.979) (positive class: 1)
```

Sumber : (Hadianto et al., 2019)

Gambar 5. *Performance Vector Neural Network*

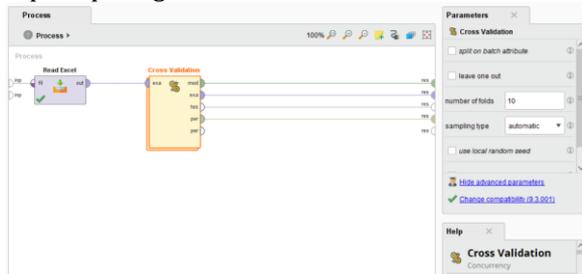
Pembahasan penelitian

Setelah pada tahap proses pengumpulan data dan pemilahan atribut yang akan digunakan di dalam *dataset* maka langkah selanjutnya adalah kita harus memasukkan datanya terlebih dahulu dengan fungsi *read excel* kedalam *tools rapid miner* lalu pembuatan permodelan *neural network* menggunakan data sebanyak 5000, tahapan proses dimulai dengan tahap permodelan kemudian memasuki tahap *learning* guna memproses *datatraining* dengan uji coba struktur, *training cycles*, *learning rate*, *momentum* kemudian diakhiri dengan *testing* untuk melihat hasil.

1. Proses Permodelan

Proses ini menggunakan *cross validation* untuk melakukan pengujian model setelah sebelumnya

model telah dibaca dengan operator *read excel*, seperti pada gambar 6.

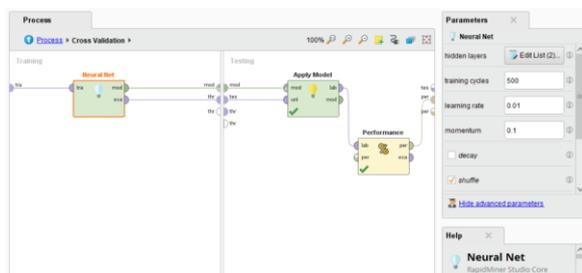


Sumber : (Hadianto et al., 2019)
 Gambar 6. Permodelan Neural Network

Pada gambar diatas dilakukan proses pengujian model yang telah dibaca menggunakan operator *read excel*, data yang telah dibaca tersebut kemudian dimasukkan kedalam operator *cross validation*, dalam penelitian ini *cross validation* yang digunakan sebesar 10 *fold validation*.

2. Proses Training

Proses selanjutnya yang dilakukan adalah proses *training*, proses ini dilakukan di dalam operator *cross validation* dengan menggunakan algoritma *neural network*, dengan algoritma ini maka data akan dibagi menjadi 2, bagian pertama digunakan sebagai *datatraining* dan bagian kedua digunakan sebagai *datatesting*, seperti pada gambar 7 dibawah ini.

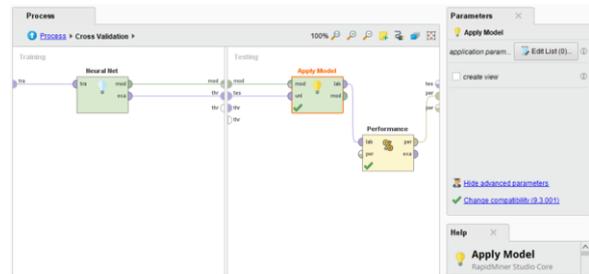


Sumber : (Hadianto et al., 2019)
 Gambar 7. Proses Training Neural Network

Pada gambar diatas proses *training* dilakukan menggunakan operator *neural network*, *training* diatas menggunakan struktur 12 - 15 - 8 - 1 dengan *training cycles* sejumlah 500, *learning rate* 0.01 dan *momentum* 0.1.

3. Proses Testing

Tahapan terakhir dari proses ini setelah dilakukan *training* adalah *testing* terhadap *dataset* menggunakan fungsi *backpropagation* yang telah dilakukan pada *datatraining* sebelumnya, proses *testing* ini dilakukan dengan cara *insert apply model* dan *performance* dengan *main criterion accuracy* dan AUC, seperti pada gambar 8 dibawah ini.



Sumber : (Hadianto et al., 2019)
 Gambar 8. Proses Testing Neural Network

4. Hasil Testing

Hasil dari *training* dan juga *testing* data terhadap 5000 data nasabah Bank yang mengajukan pinjaman dapat kita lihat pada *Performance Vector* seperti pada gambar 9 dibawah ini.

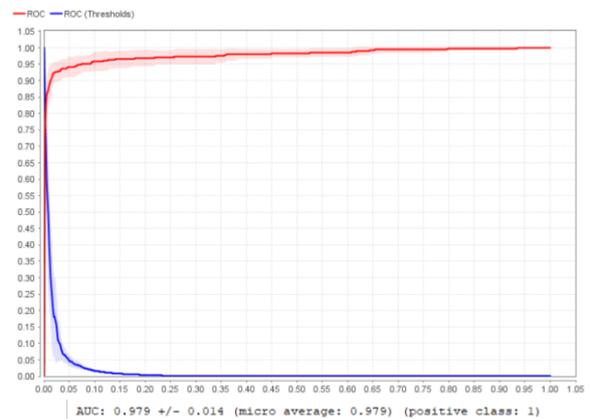
PerformanceVector

PerformanceVector:
 accuracy: 98.24% +/- 0.62% (micro average: 98.24%)

Hasil *testing* menggunakan algoritma *neural network* menunjukkan *performance accuracy* yang didapat sebesar 98.24%.

5. Hasil Uji ROC Curve

Hasil dari *training* dan juga *testing* data menggunakan *neural network* menampilkan grafik ROC dengan nilai AUC (Area Under Curve) sebesar , hasil tersebut dapat dilihat seperti pada gambar 10 dibawah ini.



Sumber : (Hadianto et al., 2019)
 Gambar 10. Nilai AUC pada grafik ROC Neural Network.

Dari gambar diatas kita dapat melihat bahwa nilai sebesar 0.979. termasuk dalam kategori “klasifikasi yang sangat baik” karena data tersebut berada diantara *range* 0.9 - 1.0 .

6. Hasil Uji Confusion Matrix

Tabel dari *confusion matrix* hasil pengolahan *dataset* menggunakan algoritma

backpropagation pada neural network adalah seperti pada gambar 11 dibawah ini.

accuracy: 98.24% +/- 0.62% (micro average: 98.24%)

	true 0	true 1	class precision
pred. 0	4491	59	98.70%
pred. 1	29	421	93.56%
class recall	99.36%	87.71%	

Dari parameter TP, FP, FN dan TN pada gambar diatas kita dapat menghitung secara manual nilai akurasi dengan menggunakan rumus pada persamaan 6, 7 dan 8. sebagai berikut.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \dots\dots\dots (6)$$

(Sokolova & Lapalme, 2009)

True Positive (tp) = 4491 record

False Negative (fn) = 59 record

True Negative (tn) = 421 record

False Positive (fp) = 29 record

TP = 4491 FN = 59

FP = 29 TN = 421

$$\text{Akurasi} = \frac{(4491+421)}{(4491+421+29+59)} \times 100\% \dots\dots\dots (7)$$

$$\text{Akurasi} = \frac{4912}{5000} \times 100\% = 98.24\% \dots\dots\dots (8)$$

Dari hasil klasifikasi menunjukkan bahwa, tingkat akurasi dengan menggunakan algoritma neural network adalah sebesar 98,24%

KESIMPULAN

Berdasarkan penelitian yang telah dilakukan menggunakan tools rapid miner 9.0 terhadap data nasabah Bank sejumlah 5000 dataset yang didapat dari machine learning repository dengan alamat web <http://www.kaggle.com> yang diuji dengan algoritma backpropagation dalam Neural Network menggunakan struktur 12 - 15 - 8 - 1 , training cycles sejumlah 500, learning rate 0.01 dan momentum 0.1 menghasilkan nilai akurasi = 98.24%, dengan AUC sebesar =0,979 yang menunjukkan bahwa klasifikasi yang dihasilkan sangat baik, sehingga nasabah dengan parameter yang ada dapat diprediksi menggunakan pola ini untuk menentukan nasabah yang layak diberikan pinjaman dari pihak Bank.

REFERENSI

Arun, K., Ishan, G., & Sanmeet, K. (2016). *Loan Approval Prediction based on Machine Learning Approach*. 18(3), 2016. <https://doi.org/10.9790/0661-1803017981>

Defu, Z., Stephen, C. H. L., & Zhimei, Y. (2008). A decision tree scoring model based on genetic algorithm and K-means algorithm. *Proceedings - 3rd International Conference on Convergence and Hybrid Information*

Technology, ICCIT 2008, 1, 1043-1047. <https://doi.org/10.1109/ICCIT.2008.110>

Fadly, M., Uddin, N., & Sutarto, H. Y. (2002). *Flutter Suppression Using Neural Networks: Design and Implementation*. (January 2017).

Hadianto, N., Novitasari, H. B., Rahmawati, A., Prasetyo, R., Miharja, J., & Komputer, I. (2019). *Klasifikasi peminjaman nasabah bank menggunakan metode neural network*. 14(2), 1-7.

Ir. Adi Sucipto, M. K. (n.d.). *CREDIT PREDICTION WITH NEURAL NETWORK ALGORITHM* Ir. Adi Sucipto , M . Kom . Sains and Technology Faculty Universitas Islam Nahdlatul Ulama Jepara. (15), 978-979.

Iriadi, N., & Nuraeni, N. (2016). kajian penerapan metode klasifikasi data mining algoritma C4.5 untuk prediksi kelayakan kredit pada bank mayapada jakarta. *Jurnal Teknik Komputer AMIK BSI (JTK)*, 2, 132-137.

Larose, D. T. (2005). *Discovering Knowledge in Data*. New Jersey: Johny Wiley & Sons, Inc.

Marhumi, S. (2017). Analisis Manajemen Perkreditan Untuk Meningkatkan Profitabilitas Pada Bank Bni Wilayah Vii Makassar. *Perspektif*, 02(01), 2355-2538. Retrieved from www.journal.unismuh.ac.id/perspektif

Putri, C. B. (2018). *Klasifikasi Nasabah Thera Bank Membeli Personal Loan Menggunakan Metode Klasifikasi Dalam Machine Learning*.

Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing and Management*, 45(4), 427-437. <https://doi.org/10.1016/j.ipm.2009.03.002>

Sucipto, A. (2012). *CREDIT PREDICTION WITH NEURAL NETWORK ALGORITHM* Ir . Adi Sucipto , M . Kom . Sains and Technology Faculty Universitas Islam Nahdlatul Ulama Jepara. (15), 978-979.

Wang, Q., Lai, K. K., & Niu, D. (2011). Green credit scoring system and its risk assesemt model with support vector machine. *Proceedings - 4th International Joint Conference on Computational Sciences and Optimization, CSO 2011*, 284-287. <https://doi.org/10.1109/CSO.2011.143>

Windarto, A. P. (2017). Implementasi Jst Dalam Menentukan. *Sains Komputer & Informatika*, 1(1), 12-23.

Yadav, S., & Shukla, S. (2016). Analysis of k-Fold Cross-Validation over Hold-Out Validation on Colossal Datasets for Quality Classification. *Proceedings - 6th International Advanced Computing Conference, IACC 2016*, (Cv), 78-83. <https://doi.org/10.1109/IACC.2016.25>

Yalidhan, M. D. (2018). Implementasi Algoritma Backpropagation Untuk Memprediksi Kelulusan Mahasiswa. *Klik - Kumpulan Jurnal Ilmu Komputer*, 5(2), 169. <https://doi.org/10.20527/klik.v5i2.152>