

CREDIT PREDICTION WITH NEURAL NETWORK ALGORITHM

Ir. Adi Sucipto, M.Kom.
Sains and Technology Faculty
Universitas Islam Nahdlatul Ulama Jepara
adismusa@yahoo.com

Abstract

One of the most crucial problems which are faced by financial institution is high level of non-performing loan. Many analysts have attempted to solve this problem by various strategy and method, but this problem still persists until now on. With regard to the spreading of credit cooperation, now it is time for the credit cooperation manager to minimize the level of non-performing loan to under 5 % as the Indonesia bank stated. On the other hand numerous credit cooperations still cannot hire an analyst because it is expensive, while the decision to approve or not a credit is a key point which determines the probability of non-performing loan. Some requirements which relevant to the credit approval are: amount of loan, time, earning, number of family and personal credit track record. This research uses the data from the "Artha Abadi" Jepara credit cooperation from the year of 2010 to 2014, the number of credit data as many as 2010 which consist of performing and non-performing loan. This research use the data mining classification method with the model of neural network which is deployed to assess the data processing accuracy with the rapid miner and then continued with the measurement use the confusion matrix, ROC curve. The result of the neural network algorithm after the test of confusion matrix, ROC curve and T-test show a very high accuracies value, and the dominant value of AUC and algorithm. The value of accuracy is 96.95 % with the number of AUC equal to 0.981 and the result of the T test show that the neural network algorithm is the most dominant result. Finally, this research reveals that the high level accuracy of the credit analysis can be done with the relatively cheap cost of computation.

Key words: Neural Network, Accuracy, Confusion Matrix, ROC Curve and T-Test

PENDAHULUAN

Koperasi Simpan Pinjam (KSP) merupakan suatu lembaga keuangan bukan bank yang bergerak dalam kegiatan simpan pinjam seperti layaknya bank, dimana ijin operasionalnya dibawah kementerian koperasi dan tidak dalam pengawasan Bank Indonesia (BI). Seperti layaknya lembaga keuangan KSP juga melakukan menghimpun dana dari para anggota dan calon anggota baik berupa tabungan maupun deposito dan menyalurkannya pada anggota dan calon anggota dengan mendapatkan keuntungan tertentu(3). Pinjaman yang diberikan dapat berupa pinjaman modal kerja, modal investasi, maupun pembelian barang-barang *consumer good* misal: pembelian TV, kulkas, kendaraan dan lain lain yang diperlukan anggota, demikian seterusnya dimana keuntungan KSP diakhir tahun yang biasa disebut Sisa Hasil Usaha (SHU).

Aktivitas kredit di lembaga financial umumnya dipengaruhi oleh faktor-faktor dari luar maupun dari dalam, seperti status ekonomi makro, situasi industry, operasi internal (3). Aktivitas KSP dalam menjalankan kegiatan usahanya sangat dipengaruhi pula oleh beberapa factor diantaranya kondisi perekonomian yang berkembang disuatu daerah tertentu, ketika kondisi perekonomian membaik maka aktivitas KSP ikut membaik demikian sebaliknya. Peta Perkreditan Indonesia di bawah bayang-bayang macet.

Penilaian kredit adalah teknik yang paling umum digunakan untuk mengevaluasi kelayakan kredit dari

pemohon kredit sehubungan dengan fitur mereka seperti: usia, pendapatan dan status pernikahan(1). Permohonan kredit biasanya didahului dengan pengisian permohonan kredit yang biasanya berisikan: nama, tempat dan tanggal lahir, pekerjaan, penghasilan, jenis usaha, tanggungan atau jumlah anggota keluarga, jaminan, status pernikahan, jumlah pinjaman, jangka waktu pinjaman, jenis pinjaman dll. Blanko tersebut harus diisi dengan benar sesuai dengan keadaan sesungguhnya. Penilaian informasi permohonan pengajuan kredit yang diperoleh dari blanko tersebut kadangkala para pengambil keputusan sulit memastikan apakah nasabah atau pemohon itu layak diberi atau tidak, apalagi belum diketahui keadaan masa lalunya, sehingga belum dapat diprediksi nasabah tersebut apabila diberi kredit akan "macet" atau "lancer"

Salah satu isu sentral yang mempengaruhi dunia perbankan saat ini adalah masalah kredit macet. Perbincangan belakangan berkembang tidak hanya membahas sebab-sebab terjadinya kredit macet. Yang lebih menarik adalah salah satu upaya penyelesaian kredit macet lewat penghapusan bukuan (*write off*) kredit macet agar kinerja bank terlihat sehat. Polemik penghapusan semakin santer setelah Gubernur Bank Indonesia Soedrajat Djiwandono, membeberkan telah dihapusbukukannya kredit macet di bank-bank pelat merah senilai Rp.4.2 triliun, dimana Rp1 triliun diantaranya dilakukan oleh BRI(15).

Dalam kaitannya dengan perencanaan, maka misi bank harus dijabarkan dalam tujuan perencanaan yang

Created with

terinci. Walaupun demikian, penyusunan perencanaan kredit secara umum harus memenuhi criteria dapat dilaksanakan (*feasible*), dapat memberikan arah yang kita kehendaki (*suitable*), dapat diterima (*acceptable*), mempunyai nilai yang berarti (*valuable*), mudah dicapai (*achievable*), dan hasilnya dapat dievaluasi/diukur (*measurable*), (19), (5). Sebenarnya dari blanko permohonan kredit dapat digunakan untuk dasar pengambilan keputusan apakah koperasi simpan pinjam akan “memberi” atau “menolak” permohonan kredit yang diajukan calon nasabah. KSP dalam merencanakan resiko kredit dari setiap nasabah biasanya hanya dilakukan analisa sederhana, hal ini ternyata sangat mengandung resiko yang besar dalam kelangsungan pembayaran angsuran setiap bulannya, sedangkanantisipasi yang biasa dilakukan hanyalah dengan melakukan pendekatan-pendekatan personal pada semua nasabah kredit. Hal ini memang tidak efektif manakala jumlah nasabah kredit jumlahnya sangat banyak. KSP memang belum cukup banyak dana untuk merekrut analis kredit seperti di perbankan mengingat kondisi keuangan yang belum memungkinkan, sehingga menjadikan tunggakan kredit yang cukup besar diatas ambang batas maksimal NPL (*Net Present Loan*) yang ditetapkan BI sebesar 5% (3).

Gaya hidup adalah konsep yang lebih baru dan lebih mudah terukur dibandingkan dengan kepribadian(18). Pendekatan perilaku ini sangatlah penting dilakukan oleh para pemangku kebijakan baik di koperasi maupun di perbankan. Apabila mendekati masalah dari perspektif pengaruh perilaku (*behavior influence perspective*), para peneliti mamfokuskan pada perilaku konsumen dan kemungkinan lengkungan yang mempengaruhi perilaku-perilaku tersebut, (11), (16).

Berikut contoh kredit macet yang diambil dari koperasi simpan pinjam Artha HPKJ Jepara mulai tahun 2010-2014, yaitu:

| Tahun | Jumlah Anggota | Kredit Macet |
|-------|----------------|--------------|
| 2010 | 747 | 11,31% |
| 2011 | 953 | 12,56% |
| 2012 | 1.001 | 12,37% |
| 2013 | 1.108 | 10,2% |
| 2014 | 1.112 | 10,1% |

Tabel 1.1 Data Kredit Macet Tahun 2010-2014 (Sumber KSP Artha HPKJ Jepara)

Tabel 1.1. Memberikan gambaran secara nyata bahwa kredit macet di KSP dari tahun ke tahun menunjukkan trend naik, hal tersebut akan signifikan dengan jumlah pemohon yang semakin hari semakin banyak, ada

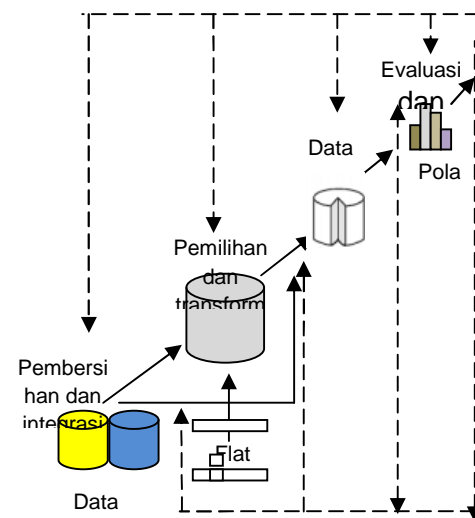
anggapan mengajukan permohonan kredit di KSP lebih mudah dibandingkan dengan di bank karena prosedur permohonan dan analisisnya tidak serumit di bank. Tujuan dari model penilaian kredit untuk menetapkan pemohon kredit “Baik” kelompok yang mungkin membayar kewajiban keuangan sepenuhnya atau “Macet” kelompok yang memiliki kemungkinan default tinggi pada kewajiban membayar (1).

TINJAUAN PUSTAKA

Data mining merupakan kumpulan data yang masih sangat heterogen, penggunaan data yang seperti ini akan sangat menyulitkan penggunaanya. Tahapan pembersihan data dalam data mining dapat digambarkan dalam Gambar 2.1. Tahap tersebut bersifat interaktif dimana pemakai terlibat langsung atau dengan perantaraan *knowledge base*. (21).

1. Pembersihan Data.

Tahapan ini akan melakukan pembersihan data, pembersihan dilakukan dengan menghapus data-data yang dinyatakan tidak relevan lagi atau noise, hal ini dilakukan supaya data yang akan digunakan benar-benar sesuai dengan perilaku data yang dibutuhkan.



Gambar 2.1. Urutan langkah Data Mining (21), (8).

2. Integrasi Data


Data yang diperlukan untuk data mining tidak hanya berasal dari suatu data base tetapi juga berasal dari beberapa database atau file teks. Hasil integrasi sering diwujudkan dalam sebuah data *warehouse* karena dengan data *warehouse*, data dikonsolidasikan dengan struktur khusus yang efisien. Selain itu data *warehouse* juga memungkinkan tipe analisa seperti OLAP.

3. Transformasi Data
 Transformasi dan pemilihan data ini untuk menentukan kualitas dari data mining, sehingga data dirubah menjadi bentuk sesuai untuk di-Mining.
4. Aplikasi Teknik Data Mining
 Aplikasi teknik data mining sendiri hanya merupakan salah satu bagian dari proses data mining. Ada beberapa teknik data mining yang sudah umum dipakai.
5. Interpretasi/Evaluasi pola yang ditemukan
 Dalam tahap ini hasil dari teknik data mining berupa pola-pola yang khas maupun model prediksi dievaluasi untuk menilai apakah hipotesa yang memang tercapai.
6. Pengetahuan
 Presentasi pola yang ditemukan untuk menghasilkan aksi tahap terakhir dari proses data mining dan bagaimana memformulasikan keputusan atau aksi dari hasil analisa yang didapat.

2.1. Algoritma Klasifikasi Neural Network

Prinsip pelatihan neural network menggunakan Backpropagation, untuk menggambarkan algoritma ini bahwa ada tiga lapisan algoritma *Neural Network* yang terdiri dari input dan output (20), (17), (14). dimana inputnya terdiri dari dua dan outputnya hanya satu seperti ditunjukkan pada gambar di bawah.

1. Isialisasi Bobot



2. Tiap input (x_{ji} $i = 1,2,3, \dots, n$) menerima sinyal dari input x_1 kemudian akan disebarkan kesemua unit hidden layer
3. Masing-masing hidden layer (Z_{ji} $j = 1,2,3, \dots, p$) jumlah dari bobot sinyal input

$$Z_{inj} = w_{bj} + \sum_{i=1}^n x_i w_{ji}$$

4. Penjumlahan bobot sinyal masuk pada unit output, dengan menggunakan fungsi sktifasi dalam menghitung sinyal output

$$y_m = w_{bo} + \sum_j w_{jo} z_j$$

5. Menghitung informasi dari error

$$\delta = (t - y) f'(y_m)$$

Menghitung bobot yang terkoreksi (w_{jo} baru)

$$\Delta w_{ja} = \eta \delta z_i$$

Menghitung bias terkoreksi

$$\Delta w_{ha} = \eta \delta$$

6. Masing-masing unit dari Hidden (Z_{ji} $J = 1,2, \dots, p$) menjumlahkan delta input

$$\delta_{in_j} = \delta w_{jo}$$

untuk menghitung error dikalikan dengan fungsi derivative aktifasi

$$\delta_j = \delta_{in_j} f'(z_{in_j})$$

Koreksi bobot

$$\Delta w_{ji} = \delta_j x_i$$

Koreksi bias

$$\Delta w_{jb} = \delta_j$$

7. Perbarui bobot dan bias

$w_{jo}(new) = w_{jo}(old) + \Delta w_{jo}$
 masing-masing unit hidden (Z_{ji} $J = 1,2,3, \dots, p$) untuk perbarui bobot dan bias

$$w_{ji}(new) = w_{ji}(old) + \Delta w_{ji}$$

Iterasi akan dilakukan diulang-ulang sampai mendapatkan nilai yang diinginkan.

| | X_1 | X_2 | y/z |
|---|-------|-------|-------|
| 1 | 0 | 0 | 0 |
| 2 | 1 | 0 | 1 |
| 3 | 0 | 0 | 1 |
| 4 | 1 | 1 | 1 |

Tabel 2.3 menggambarkan sekumpulan data yang dapat dipergunakan untuk mengajarkan algoritma *neural network*. Set data terdiri dari sinyal *input* (x_1 dan x_2) yang dapat diolah untuk mencapai target yang diinginkan (*output*) z , jaringan saraf adalah suatu proses iterative (1, 2, 3, 4) dimana dalam setiap iterasi koefisien bobot yang dimodifikasi menggunakan data baru dari set data pelatihan [12]. Modifikasi dapat dihitung menggunakan algoritma yang dijelaskan pada contoh perhitungan dibawah ini.

Dimana data pada tabel 2.3 terdiri dari satu *input layer*, dengan 2 neuron (yaitu: X_1 dan X_2) dan *hidden layer*, dengan 4 neuron (Z_1, Z_2, Z_3 dan Z_4)

Aktivasi Sigmoid:

$$z = \frac{1}{1 + e^{-z_{in}}}$$

Aktivasi sigmoid untuk 1 *output layer* dengan 1 *neuron*

$$y = \frac{1}{1 + e^{y_{in}}}$$

METODE PENELITIAN

Tahapan metode penelitian kali ini akan dilakukan langkah-langkah sebagai berikut:

2.2. Pengumpulan Data

Data yang digunakan mengambil sampel dari data nasabah kredit pada KSP Artha HPKJ Jepara dari tahun 2010-2014, dengan data sebanyak 2010 data.

2.3. Pengolahan Awal Data (Pre Processing)

Data sebesar 2010 dari KSP Artha HPKJ Jepara akan ditransformasikan untuk mendapatkan data yang benar-benar sesuai dengan format input algoritma neural network dan sesuai dengan kinuput data untuk rapid miner 4.3

2.4. Metode yang diusulkan

Metode analisa merupakan metode yang diusulkan untuk mengetahui seberapa besar tingkat akurasi dari algoritma neural network dengan menggunakan komputasi rapid miner 4.3, hasil yang diperoleh dari analisa pengujian ini akan dijadikan sebagai dasar penentuan kredit "macaet" atau "lancer"

2.5. Eksperimen dan Pengujian Methode

Data sebesar 2010 akan dibagi menjadi 2 yaitu data untuk training set sebanyak 80% dari jumlah data dan testing set sebanyak 20% dari jumlah data.

Eksperimen dan pengujian awal ini dapat dilakukan beberapa kali untuk mendapatkan hasil yang paling akurat.

2.6. Evaluasi dan Validasi Hasil


Evaluasi digunakan untuk melakukan pengamatan dan menganalisa hasil dari kerja neural network di rapid miner.

Validasi dilakukan untuk melakukan pengukuran hasil prediksi.

2.6.1. *Cros validation*, metode ini menggunakan pendekatan *training* dan *testing*. Data yang digunakan untuk pelatihan sebanyak 80%

dan data untuk testing sebanyak 20% (9), (2). Dalam pengujian ini digunakan *k-fold validation*, yaitu data dibagi dalam k sampel dalam ukuran yang sama, dimana k-1 digunakan untuk *training* dan 1 sampel sisanya untuk testing. Untuk memudahkan pemahaman misal kita gunakan k=10 data set, yang dimaksud dengan k-1 berarti 10-1=9 digunakan untuk training dan sisanya yaitu 1 data digunakan untuk testing.


Untuk menghitung rata-rata error dan standart deviasi error, dengan menggunakan 4 model klasifikasi, maka untuk mendapatkan nilai error dilakukan pengujian masing-masing model sebanyak 10 kali pada setiap kombinasi training-testing(3). Hasil pengujian ini akan didapatkan hasil rata-rata erro dan standart deviasi error untuk masing-masing model, dimana model yang mempunyai nilai error terkecil maka model itulah yang mempunyai nilai akurasi tertinggi.



Gambar 3. 1 *k-Fold Cross Validatio*

2.6.2. Pengukuran menggunakan ROC Curve dan Confusion Matrik

Pengukuran hasil validasi dengan menggunakan *ROC Curve* dan *Confusion matic* sampai mendapatkan tingkat akurasi yang tertinggi. *ROC Curve* adalah Kurva ROC banyak digunakan para peneliti untuk menilai hasil prediksi, diantaranya Hassan Sabzefari *et all*(7) Lan Yu *et all*(13), Jozef Zurada *et all*(12) *etc.* Kurva ROC menggambarkan kinerja klasifikasi tanpa memperhatikan distribusi klas atau kesalahan, pada sumbu vertical menggambarkan nilai positif (TP) dan sumbu horizontal menandakan nilai negative (FP). lihat gambar berikut:



Gambar 3. 2 Contoh Grafik ROC

Beberapa hal penting yang perlu dicatat pada Gambar 3.2, pada titik kiri bawah (0,0) merupakan titik yang tidak pernah mengeluarkan klasifikasi positif, (1,1) mewakili titik kanan atas untuk menjelaskan nilai klasifikasi positif. Titik (0,1) merupakan klasifikasi yang tidak terdapat nilai FN dan FP. Sedangkan 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. Untuk menggunakan kurva ROC dapat dilihat pada gambar 3.3. berikut:

Gambar 3.3. Contoh Kurva ROC(6).

Sebuah metode umum untuk menghitung daerah dibawah kurva ROC adalah *Area Under Curve (AUC)* dimana bidang yang berada dibawah kurve 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:

- 0,90 – 1,00 = klasifikasi yang sangat baik
- 0,80 – 0,90 = klasifikasi baik
- 0,70 – 0,80 = klasifikasi rata-rata
- 0,60 – 0,70 = klasifikasi rendah
- 0,50 – 0,60 = kegagalan

2.6.3. **Confusion matrix** adalah dalam masalah klasifikasi sering kita menentukan sesuatu yang berkaitan dengan benar atau salah(6). akurasi klasifikasi juga merupakan ukuran statistic yang menunjukkan seberapa baik klasifikasi yang dilakukan dengan mengidentifikasi obyek. Model yang digunakan untuk merumuskan *confusion matrix* model klasifikasi berdasarkan pengujian obyek yang memperkirakan benar atau salah sebagai mana dapat dilihat pada gambar 2.6

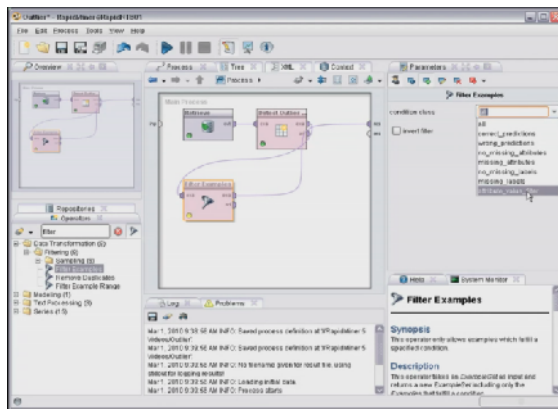
| Classification | Predicted Class | | |
|----------------|-----------------|--------------------|---------------------|
| | Class = Yes | Class = No | |
| Observed Class | Class = Yes | True Positif (TP) | Flase Negative (FN) |
| | Class = No | False Positiv (FP) | True Negative (TN) |

Gambar 3.4. Confution Matrix Model

Gambar 2.6 dapat dijelaskan bagaimana data set diklasifikasikan menjadi, *True Positif (TP)* adalah data set yang mempunyai tupel positif diklasifikasiitif positif, *False Positive (FP)* merupakan data set yang mempunyai tupel positif diklasifikasikan negative, *False Negative (FN)* adalah data set yang mempunyai tupel negative diklasifikasikan positif yang terakhir *True Negative (TN)* data set yang mempunyai tupel negative diklasifikasikan negate.

2.6.4. **Rapid miner** merupakan perangkat lunak *open source* untuk data mining dan *machine learning*, perangkat lunak ini dibuat oleh Dr. Markus Hofman, Mr. Ralf Klinkenberg dan Ms. Geraldine Gray dari Institut of Technology Blanchrdstown. Perangkat ini digunakan untuk *training model* dan menguji keakuratan model yang telah terbentuk, bahasa pemrograman yang digunakan adalah bahasa Java, dengan lisensi dari *GNU Public License*. *Rapid miner* dapat digunakan untuk berbagai macam metode, salah satu diantaranya adalah metode klasifikasi, pemakaiannyapun relatif lebih mudah karena kita hanya memasukkan data dan mengikuti aturan-aturan yang telah disiapkan dalam pemrosesan data, tanpa memasukkan coding-coding baru. Hasilnyapun dapat segera diketahui bagaimana model yang terbentuk dan sekaligus hasil pengujian untuk akurasi model yang dihasilkan. Berikut adalah gambar *rapid iner*.

Created with




Gambar : 3.5. Rapid Miner

HASIL DAN PEMBAHASAN

4.1. Analisa Pengujian Algoritma Neural Network

Sekarang kita akan membuat model dengan menggunakan algoritma *Neural Network*, seperti pada algoritma yang lain proses urutan pengujian algoritma ini juga menggunakan cara yang sama dengan pengujian model yang terdahulu dalam pengujian dengan *rapid miner*, model seperti pada gambar 4.1.1. di bawah ini:




Gambar 4.1.1. Desain Model *Neural Network*

Dari desain model seperti pada gambar 4.1., setelah data diimport dan dimasukkan dalam proses maka akan menghasilkan bentuk data seperti pada tabel 4.1.1. data inilah yang akan digunakan untuk menghasilkan model dari metode *Neural Network*, dimana setelah proses itu berlangsung dengan cara me-running, maka akan menghasilkan model yang dikehendaki.

Tabel 4.1.1. Data Hasil Pengujian *Neural Network* (selengkapnya terlampir)

| Positif | penghasilan or mdaases | emp'dan'at | pas' t'ras' | lun' ah' t'is | angka' wa | asa' t'ra | lun' rian' ur |
|---------|------------------------|------------|-------------|---------------|-----------|-----------|---------------|
| 1 | 550000 | 3.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 2 | 170000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 3 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 4 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 5 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 6 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 7 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 8 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 9 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 10 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 11 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 12 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 13 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 14 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 15 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 16 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 17 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 18 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 19 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 20 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |
| 21 | 150000 | 1.000 | 0.00 | ajar | 24 | 80000 | 10 |

Dalam tabel 4.1.1. dapat memberikan informasi bahwa dari data yang dimasukkan kedalam metode *Neural Network* dengan *apply model* pada *rapid miner* menunjukkan bahwa muncul prediksi yang akan menentukan apakah metode *Neural Network* dapat memberikan prediksi terbaik. Sedangkan gambar 4.1.2. merupakan model hasil dari pengujian metode *Neural Network* juga dapat memberikan informasi pada kita bahwa dalam metode ini yang menjadi informasi penting adalah tentang *hidden layer*.



Gambar 4.1.2. Model Hasil Pengujian *Neural Network*


Selengkapnya informasi dari model tersebut adalah pada sisi input terdapat enam atribut dengan perincian jumlah pinjaman, jangka waktu, jasa pinjaman, jumlah angsuran, penghasilan dan klas status, dimana atribut tersebut akan membentuk lapisan input (x) yang dapat diberi bobot x_1, x_2, \dots, x_6 . Sedangkan pada posisi hidden layer juga akan membentuk lapisan tersembunyi (z), jarak antara lapisan input dengan lapisan tersembunyi mempunyai bobot yang disebut dengan matrik bobot pertama yang diberi insial $v_{11}, v_{12}, \dots, v_{16}$. Selanjutnya pada posisi output akan muncul apa yang disebut lapisan output (y), dimana jarak antara (y) dan (z) dapat dihitung dengan menggunakan matrik bobot kedua yaitu w_1, w_2, \dots, w_6 , setelah selesai perhitungan w maka akan dapat dihitung nilai outputnya dalam hal ini adalah Lancar atau Macet.

4.2. Evaluasi dan Validasi


Penelitian ini bertujuan untuk menguji akurasi dari analisa kredit dengan menggunakan algoritma *neural network* data yang dianalisa adalah data kredit yang diperoleh dari koperasi simpan pinjam yang telah mendapatkan persetujuan manajemen koperasi. Dengan bantuan *rapid miner* ternyata dapat diketahui algoritma yang mempunyai akurasi yang sangat tinggi.

4.3. Pengujian Model Neural Network

Pengujian model *Neural Network* dengan menggunakan testing dan validasi seperti ditunjukkan pada gambar 4.3.1. dan gambar 4.3.2. dapat menghasilkan nilai *accuracy* = 72,00%, *precision* = 63,08% dan *recall* = 69,81% dengan AUC sebesar = 0,800 seperti ditunjukkan pada gambar di bawah ini:



Gambar 4. 3.1. Model Testing *Neural Network*



Gambar 4. 3.2.1 Desain Validasi *Neural Network*

| accuracy: 96.95% +/- 2.30% (mikro: 96.95%) | | | |
|--|-------------|------------|--------|
| | true Lancer | true Macet | class |
| pred Lancer | 387 | 38 | 95.86% |
| pred Macet | 3 | 576 | 98.96% |
| class recall | 39.11% | 33.81% | |

Gambar 4.3.3. Nilai *Accuracy* dari *Neural Network*

Gambar 4.3.3. memberikan informasi pada kita bahwa hasil *accuracy* dari metode klasifikasi *Neural Network* sebesar = 96,95% ini menunjukkan bahwa hasil akurasi yang diperoleh masuk dalam katagori sangat baik.

| precision: 98.64% +/- 1.67% (mikro: 98.63%) (positive class: Macet) | | | |
|---|-------------|------------|--------|
| | true Lancer | true Macet | class |
| pred Lancer | 387 | 38 | 95.86% |
| pred Macet | 3 | 576 | 98.96% |
| class recall | 39.11% | 33.81% | |

Gambar 4.3.4. Nilai *Precision* dari *Neural Network*

Gambar 4.3.4. memberikan informasi pada kita bahwa hasil *precision* dari metode klasifikasi *Neural Network* sebesar = 98,64% ini menunjukkan bahwa hasil akurasi yang diperoleh masuk dalam katagori sangat baik.

| recall: 93.80% +/- 5.36% (mikro: 93.81%) (positive class: Macet) | | | |
|--|-------------|------------|--------|
| | true Lancer | true Macet | class |
| pred Lancer | 387 | 38 | 95.86% |
| pred Macet | 3 | 576 | 98.96% |
| class recall | 39.11% | 33.81% | |


Gambar 4.3.5. Nilai *Recall* dari *Neural Network*

Gambar 4.3.5. memberikan informasi pada kita bahwa hasil *recall* dari metode klasifikasi *Neural Network* sebesar = 93,80% ini menunjukkan bahwa hasil akurasi yang diperoleh masuk dalam katagori sangat baik.

Tabel 4.1.1 *Performance Vector Neural Network*

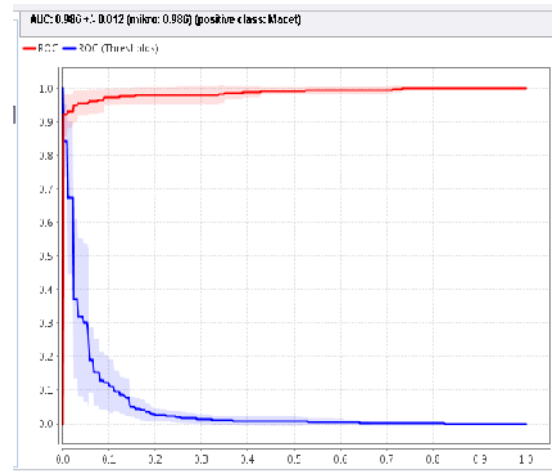
| PerformanceVector | |
|---|--|
| PerformanceVector: | |
| accuracy: 96.95% +/- 2.30% (mikro: 96.95%) | |
| ConfusionMatrix: | |
| True: Lancer Macet | |
| Lancer: 387 38 | |
| Macet: 3 576 | |
| precision: 98.64% +/- 1.67% (mikro: 98.63%) (positive class: Macet) | |
| ConfusionMatrix: | |
| True: Lancer Macet | |
| Lancer: 387 38 | |
| Macet: 3 576 | |
| recall: 93.80% +/- 5.36% (mikro: 93.81%) (positive class: Macet) | |
| ConfusionMatrix: | |
| True: Lancer Macet | |
| Lancer: 387 38 | |
| Macet: 3 576 | |
| AUC (optimistic): 0.956 +/- 0.012 (mikro: 0.956) (positive class: Macet) | |
| AUC: 0.956 +/- 0.012 (mikro: 0.956) (positive class: Macet) | |
| AUC (pessimistic): 0.586 +/- 0.012 (mikro: 0.586) (positive class: Macet) | |

Tabel 4.3.1. memberikan informasi secara keseluruhan tentang hasil dari validasi dengan metode klasifikasi *Neural Network*, disamping hasil *accuracy*, *precision* dan *recall*, juga nilai AUC dan masih ada informasi penting dalam *performance vector* ini yaitu *confusion matrix* pada masing-masing katagori lancer dan macet dengan nilai jelas.




Gambar 4. 3.6. Hasil AUC Optimistic dari Neural Network

Gambar 4.30 menggambarkan grafik area under curve (AUC) optimistic hasil validasi Neural Network dengan nilai yang tertera dalam gambar sebesar = 0,986



Gambar 4. .8. AUC Neural Network

Gambar 4.3.8. menggambarkan grafik area under curve (AUC) hasil validasi Neural Network dengan nilai yang tertera dalam gambar sebesar = 0,986



Gambar 4.3 .7. AUC Pesimistic dari Neural Network

Gambar 4.3.7. menggambarkan grafik area under curve (AUC) pesimistic hasil validasi Neural Network dengan nilai yang tertera dalam gambar sebesar = 0,986

KESIMPULAN:

Hasil penelitian yang dilakukan dengan menggunakan algoritma neural network dari 2010 data dari KSP Artha HPKJ Jepara dengan menggunakan rapid miner untuk mendeteksi kredit macet pada KSP dapat dijelaskan bahwa nilai akurasi dari algoritma neural network sebesar 96,95%. Hasil akurasi sebesar 96.95% menunjukkan bahwa algoritma neural network sangat baik digunakan untuk memprediksi kredit macet atau lincer *witen (2011)* pada KSP.

Sedangkan nilai grafik AUC menggambarkan grafik area under curve (AUC) pesimistic hasil validasi Neural Network dengan nilai yang tertera dalam gambar sebesar = 0,986, artinya hasil dari pengujian ini menunjukkan hasil validasi yang mendekati sempurna.

Saran

Kesimpulan yang dapat diambil dari pengujian dengan menggunakan algoritma neural network yang telah divalidasi menggunakan AUC, ROC dan *Confusion Matric* yang diuji menggunakan soft ware rapid miner dan hasilnya menunjukkan hasil yang mendekati nilai sempurna yaitu 96,95% nilai akurasinya serta nilai AUC sebesar 0,986%. Dari hasil ini terdapat banyak hal yang dapat disimpulkan kepada para pengambil keputusan diantaranya:

1. Dari data yang disajikan para surveyor dalam menyajikan data calon nasabah kredit baru dapat diketahui atau dideteksi bahwa calon nasabah tersebut akan mengalami kemungkinan macet atau lincer.
2. Dalam pengujian tersebut dapat ditambah beberapa parameter yang dapat melengkapi

Created with

- keadaan calon nasabah, karena semakin banyak parameter yang digunakan untuk pengujian ini akan semakin akurat hasilnya.
3. Akurasi algoritma neural network masih dapat ditingkatkan hasilnya dengan menambahkan parameter baru yang sesuai dengan keadaan calon nasabah, karena sifat pengujian dengan bantuan *rapid miner* ini masih tergantung dengan jumlah parameter dan jumlah nasabah yang dijadikan pengujian.
 4. Pengujian dengan bantuan *rapid miner* juga dapat digunakan untuk membandingkan antara algoritma neural network dengan algoritma lainnya sehingga hasil pengujian dengan cara membandingkan akan mempunyai akurasi yang lebih baik hanya saja membutuhkan waktu yang lebih panjang.
 5. Bagi pengambil keputusan di koperasi simpan pinjam dapat menerima atau menolak nasabah kredit baru sehubungan dengan hasil prediksi perilaku nasabah.

REFERENSI

1. Arifin Sitio and Halomoan Tamba, *Koperasi Teori dan Praktik*. Jakarta, Indonesia: Erlangga, 2001.
2. Adel Lahsasna, Raja Noor Ainon, and The Ying Wah, "Credit Scoring Models Using Soft Computing Methods: A Survey," *The International Arab Journal of Information Technology*, vol. 7, no. 2, April 2010.
3. Budi Santosa, *Data mining Teknik Pemanfaatan Data Untuk Keperluan Bisnis Teori dan Aplikasi*, 1st ed. Surabaya, Indonesia: Graha Ilmu, 2007
4. Budi Warsito, *Kapita Selecta Statistika Neural Network*, Perdana, Ed. Semarang: BP Undip, 2009.
5. Dr. (Cand) Taswan, SE, M.Si, "Manajemen Perbankan" Konsep, Teknik dan Aplikasi, Edisi Kedua UPP STIM YKPN, Yogyakarta, 2010.
6. Florin Gorunescu, *Data Mining Concept, Model and Technique*, 12th ed., Prof. Janusz Kecprzyk and Prof. Lakhmi C Jain, Eds. Verlag Berlin Heidelberg: Springer, 2011.
7. Hassan Sabzevari, Mehdi Soleymani, and Eaman Noorbakhsh, "A comparison Between Statistical and Data Mining Method for Credit Scoring in Case of Limited Available Data," p. 8, June 2008.
8. Hengwen Cai, Hong Yu, Xiaolei Huang, and Xiaorong Hu, "A Comparative Study on Data Mining Algorithm for Individual Credit Risk Evaluation," in *Management of e-Commerce and e-Government, International Conference on*, Nanchang, 330029, October, 2010, pp. 35-38.
9. Ian H Witten, Eibe Frank, and Mark A Hall, *Data Mining Practical Machine Learning Tool and Techniques*, Third Edition ed. Burlington, United States of America: Elsevier Inc., 2011.
10. Jiawei Hand and Micheline Kamber, *Data Mining Concept and Techniques*, Second Edition ed., Jim Gray, Ed. San Francisco, United States of America: Elsevier Inc., 2006.
11. John C. Mowen / Michael Minor, "Perilaku Konsumen" Jilid 2 Edisi Kelima, Erlangga, 2002
12. K Niki Kunene and Jozef Zurada, "Comparism of the Performace of Computational Itelligence Methods for Loan Granting Decisions," in *Hawaii International Confrence on System Sciences*, Louisville, Januari, 2011, pp. 1-10.
13. Lan Yu, Guoqing Chen, Andy Koronios, Shiwu Zhu, and Xunhua Guo, "Application and Comparism of Classification Techniques in Controlling Credit Risk," *Recent Advances ini Data Mining of Enterprise Data: Algorithms and Applications*, pp. 111-145, May 2007.
14. Lin Lin and Nantian Huang, "Credit Risk Assessment Using BP Neural Network with Demspster-Shafer Theory," *International Conference on Artifial Intellegence*, pp. 397-401, 2009.
15. Mudrajat Kuncoro, Suhardjono, "Manajemen Perbankan" Teori dan Aplikasi, Edisi Kedua, Fakultas Ekonomi dan Bisnis UGM, 2012
16. Prof. Dr. Ir. Ujang Sumarwan, M.Sc, "Perilaku Konsumen" , Edisi Kedua, Ghalia Indonesia, 2011.
17. Rong-Zhou Li, Su-Lin Pang, and Jian-Min Xu, "Neural Network Credit-Risk Evaluation Model Based On Back-Propagation Algorithm," *Prosedings of the First International Conference on Machine Learning and Chbernetic, Beijing, 4-5 November 2002*, p. 17021706, November 2002.
18. Santoso S, *Statistik Parametrik-Konsep dan Aplikasi dengan SPSS*. Jakarta: PT. Eka Media Komputindo, 2010

Created with

19. Teguh Pudjo Muljono, *Manajemen Perkreditan Bagi Bank Komersial*, 4th ed. Yogyakarta, Indonesia: BPFY-Yogyakarta, 2001
20. T Sutejo, Edy Mulyanto, and Vincent Suhartono, *Kecerdasan Buatan*, Perdana ed. Semarang: Andi Offset, 2011.
21. Xindong Wu and Vipin Kumar, *The Top Ten Algorithms in Data Mining*, 1st ed. Minnesota, USA: CRC Press Taylor & Francis Group, 2009.
22. Yi Jiang, Qingshan Chen, Hongyi Huang, and Defu Zhang, "A Comparison Study of Credit Scoring Models," in *International Conference on Natural Computation*, Xiame, August, 2007, pp. 15-18.