

# IMPLEMENTASI NEURAL NETWORK PADA PREDIKSI PENDAPATAN RUMAH TANGGA

Evy Priyanti

Program Studi Komputerisasi Akuntansi

Akademik Manajemen Informatika dan Komputer Bina Sarana Informatika (AMIK BSI)

Jl. Rs Fatmawati no 24 Jakarta

[evy.evp@bsi.ac.id](mailto:evy.evp@bsi.ac.id)

## ABSTRAK

Pendapatan rumah tangga sangat penting dalam kehidupan sehari-hari, oleh karena itu, untuk memprediksi bagaimana pendapatan rumah tangga dapat ditingkatkan di sini, penulis menggunakan algoritma jaringan syaraf tiruan untuk memprediksi faktor-faktor yang dapat mempengaruhi pendapatan rumah tangga. Algoritma jaringan syaraf tiruan merupakan teknik peramalan yang paling umum digunakan, karena algoritma Neural Network dapat cepat dan akurat, banyak peneliti menggunakan jaringan syaraf tiruan untuk memecahkan masalah peramalan. Jaringan Syaraf Tiruan memiliki keunggulan bahwa jaringan syaraf tiruan dapat mengatasi masalah nonlinier, memiliki toleransi yang tinggi terhadap data yang mengandung noise dan mampu menangkap hubungan yang sangat kompleks antara variabel prediktor dan keluaran. Pada data pendapatan rumah tangga ini algoritma jaringan syaraf tiruan dapat memprediksi jumlah pendapatan dengan akurasi sebesar 83,62%. Nilai akurasi yang didapat sangat tinggi dan dapat membantu dalam menata keuangan di setiap rumah tangga, sehingga jaringan syaraf tiruan dapat memecahkan masalah dalam memprediksi pendapatan rumah tangga di berbagai negara di dunia sesuai dengan data dari UCI dataset dibandingkan menggunakan algoritma KNN yang nilai akurasinya sebesar 79.18%.

**Kata Kunci :** Data Mining, Neural Network, Rumah Tangga

## ABSTRACT

*Household income is very important in everyday life, therefore, to predict how household incomes can be improved here, the authors use artificial neural network algorithms to predict factors that may affect household incomes. Artificial neural network algorithms are the most commonly used forecasting techniques, because the Neural Network algorithm can be fast and accurate, many researchers using artificial neural networks to solve forecasting problems. Artificial Neural Networks have the advantage that artificial neural networks can overcome nonlinear problems, have high tolerance to noise-containing data and be able to capture the very complex relationship between predictor and output variables. In this household income data artificial neural network algorithm can predict the amount of income with an accuracy of 83.62%. The accuracy of the value obtained is very high and can help in managing the finances in every household, so that neural networks can solve the problem in predicting household income in various countries in the world according to data from UCI dataset than using KNN algorithm whose accuracy value is 79.18%.*

**Keyword :** Data Mining, Household, Neural Network

### 1. Pendahuluan

Data sensus pendapatan yang dilakukan oleh Ronny Kohavi and Barry Becker pada

sensus Beureu didapatkan beberapa variabel yang menghasilkan data pendapatan untuk beberapa Negara didunia dengan besaran pendapatan rumah tangga yang lebih besar

dari \$50.000/tahun, lebih besar sama dengan \$50.000/tahun dan kurang sama dengan dari \$50.000/tahun.

Data yang didapat terdiri dari beberapa atribut yaitu *age*, *workclass*, *state-gov*, *fnlwgt*, *education*, *education-num*, *marital-status*, *occupation*, *relationship*, *race*, *sex*, *capital-gain*, *capital-loss*, *hours-per-week*, *native-country*.

Beberapa kriteria yang mengungkapkan bahwa secara umum pendapatan rumah tangga yang lebih dari \$50.000/tahun didapatkan dengan beberapa kriteria dibawah ini

Jenis keluarga, bahwasannya keluarga yang utuh yang minimal terdiri dari suami dan istri dalam satu atap memiliki peluang mendapatkan pendapatan rumah tangga yang lebih besar dibandingkan dengan jenis keluarga yang tidak utuh.

Pendidikan, seseorang yang memiliki pendidikan yang lebih tinggi memiliki peluang untuk mendapatkan penghasilan yang lebih tinggi.

Lama bekerja, semakin lama seorang pekerja semakin besar pula penghasilan yang didapatkannya dan ini membuktikan bahwa seseorang dengan pengalaman yang lebih banyak dapat menghasilkan pendapatan yang lebih banyak pula.

Menurut Liao dan Triantaphyllou (2007:126) Neural Network (NN) adalah teknik peramalan yang paling umum digunakan, karena Neural Network bisa cepat dan akurat, banyak peneliti menggunakan Neural network untuk memecahkan masalah peramalan. Neural Network mempunyai kelebihan yaitu jaringan syaraf mampu menyelesaikan problem nonlinear, mempunyai toleransi yang cukup tinggi terhadap data yang mengandung noise dan mampu menangkap hubungan yang sangat kompleks antara variabel-variabel predictor dan outputnya.

Pada penelitian sebelumnya Valentin Mihov dalam penelitiannya yang berjudul *Adult Income Dataset Analysis with IPython* menggunakan *Learning Model Logistic regression* pada tahun 2015 yang hanya memisahkan antara data yang berhubungan dengan data yang tidak berhubungan. Fitur yang bertanda negatif terdiri dari Never married, Own child, priv-house-serv dan

divorce sedangkan fitur yang bernilai positif terdiri dari capital gain, married-civ-spouse, age, hours per week, dan exec-managerial, selanjutnya fitur yang bernilai negatif akan dipisahkan supaya proses analisis dapat berjalan lebih baik. Penelitian juga dilakukan oleh Topiwala dalam penelitiannya yang berjudul *Machine Learning on UCI Adult data set using various classifier algorithms and scaling up the accuracy using extreme gradient boosting* pada tahun 2013, Topiwala meneliti data *Adult* dengan menggunakan algoritma *K-Nearest Neighbor* (KNN) dengan nilai akurasi sebesar 79.18%.

Pada penelitian kali ini akan diteliti bagaimana neural network dapat meningkatkan akurasinya dalam penilaian pendapatan rumah tangga disetiap Negara dengan berbagai atribut yang ada pada Adult UCI Dataset.

## 2. Metode Penelitian

Dataset yang digunakan oleh peneliti adalah dataset dari UCI mengenai pendapatan rumah tangga di tiap Negara. Dengan atribut-atribut sebagai berikut:

*age*: continuous.

*workclass*: Private, Self-emp-not-inc, Self-emp-inc, Federal-gov, Local-gov, State-gov, Without-pay, Never-worked.

*fnlwgt*: continuous.

*education*: Bachelors, Some-college, 11th, HS-grad, Prof-school, Assoc-acdm, Assoc-voc, 9th, 7th-8th, 12th, Masters, 1st-4th, 10th, Doctorate, 5th-6th, Preschool.

*education-num*: continuous.

*marital-status*: Married-civ-spouse, Divorced, Never-married, Separated, Widowed, Married-spouse-absent, Married-AF-spouse.

*occupation*: Tech-support, Craft-repair, Other-service, Sales, Exec-managerial, Prof-specialty, Handlers-cleaners, Machine-op-inspct, Adm-clerical, Farming-fishing, Transport-moving, Priv-house-serv, Protective-serv, Armed-Forces.

*relationship*: Wife, Own-child, Husband, Not-in-family, Other-relative, Unmarried.

*race*: White, Asian-Pac-Islander, Amer-Indian-Eskimo, Other, Black.

*sex*: Female, Male.

*capital-gain*: continuous.

*capital-loss*: continuous.

*hours-per-week*: continuous.

native-country: United-States, Cambodia, England, Puerto-Rico, Canada, Germany, Outlying-US(Guam-USVI-etc), India, Japan, Greece, South, China, Cuba, Iran, Honduras, Philippines, Italy, Poland, Jamaica, Vietnam, Mexico, Portugal, Ireland, France, Dominican-Republic, Laos, Ecuador, Taiwan, Haiti, Columbia, Hungary, Guatemala, Nicaragua, Scotland, Thailand, Yugoslavia, El-Salvador, Trinadad&Tobago, Peru, Hong, Holand-Netherlands.

Berikut penjelasannya:

Usia terdiri dari usia 17-90 tahun.

Kelas pekerja terdiri dari= pegawai swasta, wiraswasta yang bukan dari perusahaan, pemerintah federal, pemerintah local, pemerintah pusat, pekerja tanpa bayaran, dan tidak pernah bekerja.

Sample=nomor sample

Pendidikan= Sarjana, Beberapa perguruan tinggi, kelas 11, HS-grad, Prof-school, Assoc-acdm, Assoc-voc, 9th, 7th-8th, 12th, Masters, 1st-4th, 10th, Doctorate, 5th-6th, Prasekolah

Nomor pendidikan= terdiri dari 1 sampai dengan 16.

Status pernikahan= Married-civ-spouse=menikah dengan warga sipil, Divorced= bercerai, Never-married= memiliki pasangan tetapi tidak menikah secara resmi, Separated= terpisah, Widowed= janda atau duda yang belum menikah lagi, Married-spouse-absent= pasangan yang menikah akan tetap tidak satu rumah tangga bisa jadi karena dipisahkan atau belum resmi bercerai akan tetapi sudah tidak 1 rumah, Married-AF-spouse= menikah dengan angkatan

Jenis keluarga juga terdiri dari dua bagian yaitu keluarga lengkap dan keluarga tidak

lengkap. Yang terdiri dari keluarga tidak lengkap adalah divorce, never-married, separated, married -spouse-absent

Keluarga lengkap terdiri dari married-civ-spouse dan married-AF-spouse.

Pekerjaan: Tech-support, Craft-repair, Other-service, Sales, Exec-managerial, Prof-specialty, Handlers-cleaners, Machine-op-inspct, Adm-clerical, Farming-fishing, Transport-moving, Priv-house-serv, Protective-serv, Armed-Forces.

hubungan: istri, anak kandung, suami, bukan bagian dari keluarga inti, relasi lainnya, tidak menikah.

ras: White, Asian-Pac-Islander, Amer-Indian-Eskimo, Other, Black.

jenis kelamin: wanita, pria.

keuntungan dalam bentuk uang: bernilai antara 1 sampai dengan 99.999

kehilangan modal: bernilai antara 1 sampai dengan 3.004.

jam per minggu: bernilai antara 1 sampai dengan 99.

Negara asal: United-States, Cambodia, England, Puerto-Rico, Canada, Germany, Outlying-US(Guam-USVI-etc), India, Japan, Greece, South, China, Cuba, Iran, Honduras, Philippines, Italy, Poland, Jamaica, Vietnam, Mexico, Portugal, Ireland, France, Dominican-Republic, Laos, Ecuador, Taiwan, Haiti, Columbia, Hungary, Guatemala, Nicaragua, Scotland, Thailand, Yugoslavia, El-Salvador, Trinadad&Tobago, Peru, Hong, Holand-Netherlands.

Berikut adalah data pendapatan rumah tangga di beberapa Negara berdasarkan Adult UCI dataset pada Tabel 3.1. Data Pendapatan Rumah Tangga:

**Tabel 3.1 Data Pendapatan Rumah Tangga**

age	workclass	fnlwgt	education	education-num	marital-status	occupation	relationship	race	sex	captial-gain	captial-loss	hours-per-week	native-country	income
39	1	775	1	13	1	1	1	1	1	217	4	0	40	1=50K
50	2	833	1	13	2	2	2	1	1	0	0	13	1	1=50K

3	8	215		2	9	3	3	1	1	1	0	0	40	1	1=5 OK
5	3	234		3	7	2	3	2	2	1	0	0	40	1	1=5 OK
2	8	338		3	13	2	4	3	2	2	0	0	40	2	1=5 OK
3	7	284		4	14	2	2	3	1	2	0	0	40	1	1=5 OK
4	9	160		5	5	4	5	1	2	2	0	0	16	3	1=5 OK
5	2	209		2	9	2	2	2	1	1	0	0	45	1	150 K
3	1	457		4	14	1	4	1	1	2	140		50	1	150 K
4	2	159		1	13	2	2	2	1	1	517		40	1	150 K
3	7	280		6	10	2	2	2	2	1	0	0	80	1	150 K
3	0	141		1	13	2	4	2	3	1	0	0	40	4	150 K
2	3	122		1	13	1	1	4	1	2	0	0	30	1	1=5 OK
3	2	272		7	12	1	6	1	2	1	0	0	50	1	1=5 OK
4	0	121		8	11	2	7	2	3	1	0	0	40	1	150 K
3	4	245		9	4	2	8	2	4	1	0	0	45	5	1=5 OK
2	5	176		2	9	1	9	4	1	1	0	0	35	1	1=5 OK
3	2	186		2	9	1	10	5	1	1	0	0	40	1	1=5 OK
3	8	288		3	7	2	6	2	1	1	0	0	50	1	1=5 OK
4	3	292		4	14	3	2	5	1	2	0	0	45	1	150 K
4	0	193		10	16	2	4	2	1	1	0	0	60	1	150 K
3	3	646													

Sumber : Uci dataset (1996)

Dikarenakan fungsi aktivasi yang dipakai fungsi aktivasi sigmoid (biner), data harus ditransformasikan dulu karena batasan keluaran fungsi aktivasi sigmoid adalah [0,1], tapi akan lebih baik jika ditransformasikan ke interval yang lebih kecil, misal pada interval [0.1,0.9] (Siang ,2009:p25). Maka, pada data pendapatan rumah

tangga yang ada dilakukan transform data dengan interval [0.1,0.9], dengan rumus sebagai berikut:

$$x' = \frac{0.8(x - a)}{b - a} + 0.1$$

Berikut perhitungan transform dengan menggunakan fungsi aktivasi sigmoid:

Berdasarkan data pendapatan rumah tangga dengan atribut age diketahui

nilai minimum (a) = 17

nilai maximum (b) = 90

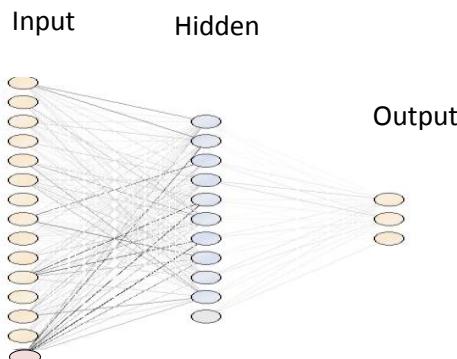
pendapatan rumah tangga yang akan di transform ( $x$ ) =  $x' = \frac{0.8(39-17)}{90-17} + 0.1$

$$x' = \frac{0.8(22)}{73} + 0.1$$

$$x' = 0.889$$

Selanjutnya akan di uji dan dilatih apakah dengan nilai transform pendapatan rumah tangga dengan nilai atribut 39 dan nilai

Nilai uji dataset menggunakan algoritma neural network didapatkan data akurasi yang terlihat pada gambar 3.1. sebagai berikut:



**Gambar 3.1. Arsitektur Jaringan yang didapat dari Hasil Eksperimen Neural Network**

Pada gambar 3.1. terlihat 10 buah hidden layer dan 1 buah Threshold untuk mendapatkan nilai akurasi sebesar 83.62% pada algoritma Neural Network dengan 3 buah output yang akan dihasilkan dan 14 buah input yang didapat dari fitur age, workclass, fnlwgt, education, education-num, marital-status, occupation, relationship, race, sex, capital-gain, capital-loss, hours-per-week, native-country dan 1 buah Threshold. Untuk nilai dari setiap Node sebagai berikut:

Hidden 1

=====

Node 1 (Sigmoid)

-----

age: 22.222

transform 0.889 memiliki nilai akurasi yang tinggi.

### 3. Hasil dan Pembahasan

Eksperimen yang dilakukan dengan penentuan beberapa parameter penunjang seperti training cycle, learning rate, momentum dan hidden layer perlu dilakukan untuk mendapatkan hasil yang lebih akurat.

Setelah itu akan muncul nilai akurasi, precision, recall, AUC (Optimistic), AUC, AUC (Pessimistic) yang didapat dari hasil eksperimen yang telah dilakukan.

workclass: 3.716  
fnlwgt: 4.580  
education: -0.895  
education-num: 0.222  
marital-status: -3.815  
occupation: 4.936  
relationship: -5.273  
race: -7.233  
sex: -0.695  
capital-gain: 5.477  
capital-loss: 4.185  
hours-per-week: 4.704  
native-country: -4.146  
Bias: -11.066

Node 2 (Sigmoid)

-----  
age: -24.146  
workclass: 2.636  
fnlwgt: -10.123  
education: 3.777  
education-num: 0.179  
marital-status: 5.624  
occupation: 1.646  
relationship: -2.425  
race: 1.115  
sex: 1.947  
capital-gain: -8.324  
capital-loss: 2.471  
hours-per-week: -2.963  
native-country: -1.042  
Bias: -23.870

Node 3 (Sigmoid)

-----  
age: -5.430  
workclass: 1.000  
fnlwgt: -0.433  
education: 0.356

education-num: -1.337  
marital-status: -0.737  
occupation: -0.611  
relationship: 28.700  
race: -3.215  
sex: 0.132  
capital-gain: 1.829  
capital-loss: -1.070  
hours-per-week: 11.174  
native-country: -2.435  
Bias: -3.891

#### Node 4 (Sigmoid)

-----  
age: 5.685  
workclass: -0.244  
fnlwgt: 8.074  
education: -10.888  
education-num: 1.145  
marital-status: 8.611  
occupation: 3.348  
relationship: 7.177  
race: 2.783  
sex: 8.539  
capital-gain: -6.487  
capital-loss: 4.542  
hours-per-week: -7.812  
native-country: 5.342  
Bias: -8.231

#### Node 5 (Sigmoid)

-----  
age: -0.271  
workclass: -1.423  
fnlwgt: 3.078  
education: -1.513  
education-num: -9.966  
marital-status: -3.185  
occupation: 1.139  
relationship: -4.481  
race: 5.265  
sex: -3.238  
capital-gain: -39.843  
capital-loss: -3.972  
hours-per-week: 0.392  
native-country: 3.199  
Bias: -31.051

#### Node 6 (Sigmoid)

-----  
age: -7.201  
workclass: -11.109  
fnlwgt: -2.026  
education: 3.933

education-num: -18.864  
marital-status: -10.307  
occupation: 3.983  
relationship: -1.328  
race: 6.007  
sex: 12.413  
capital-gain: -20.721  
capital-loss: -5.367  
hours-per-week: -7.670  
native-country: 2.496  
Bias: -11.718

#### Node 7 (Sigmoid)

-----  
age: 0.960  
workclass: -3.315  
fnlwgt: 2.722  
education: -0.272  
education-num: -0.826  
marital-status: 5.061  
occupation: 0.643  
relationship: 3.900  
race: 1.692  
sex: -0.352  
capital-gain: 34.186  
capital-loss: 2.727  
hours-per-week: -2.107  
native-country: 0.974  
Bias: 39.299

#### Node 8 (Sigmoid)

-----  
age: -4.320  
workclass: 0.551  
fnlwgt: 5.374  
education: -2.605  
education-num: -4.247  
marital-status: 12.725  
occupation: -0.557  
relationship: -27.932  
race: 3.602  
sex: 1.311  
capital-gain: -15.310  
capital-loss: 0.573  
hours-per-week: -10.066  
native-country: 1.295  
Bias: -22.935

#### Node 9 (Sigmoid)

-----  
age: 4.394  
workclass: 2.226  
fnlwgt: -4.166  
education: 6.004

education-num: -4.086  
marital-status: 6.388  
occupation: 0.076  
relationship: 7.346  
race: -2.660  
sex: 6.604  
capital-gain: -0.243  
capital-loss: 1.737  
hours-per-week: -2.883  
native-country: -1.398  
Bias: -10.478

Node 10 (Sigmoid)

age: -0.597  
workclass: -6.270  
fnlwgt: 2.102  
education: -2.025  
education-num: -13.238  
marital-status: 12.106  
occupation: -1.736  
relationship: 6.464  
race: 0.073  
sex: -2.625  
capital-gain: -9.128  
capital-loss: 0.803  
hours-per-week: -20.981  
native-country: -8.192  
Bias: -16.149

Output

Class ' $\leq 50K$ ' (Sigmoid)

Node 1: 2.202  
Node 2: 1.918  
Node 3: 5.125  
Node 4: 8.848  
Node 5: 3.301  
Node 6: 1.703  
Node 7: -4.852  
Node 8: 2.791  
Node 9: 5.925  
Node 10: 3.626  
Threshold: -3.293

Class ' $>50K$ ' (Sigmoid)

Node 1: -2.202  
Node 2: -1.918  
Node 3: -5.126  
Node 4: -8.849  
Node 5: -3.301  
Node 6: -1.703

Node 7: 4.853  
Node 8: -2.791  
Node 9: -5.925  
Node 10: -3.626  
Threshold: 3.293

Class ' $\geq 50$ ' (Sigmoid)

Node 1: -0.929  
Node 2: -1.012  
Node 3: -0.978  
Node 4: -0.935  
Node 5: -1.827  
Node 6: -1.184  
Node 7: -1.146  
Node 8: -1.013  
Node 9: -0.962  
Node 10: -0.899  
Threshold: -5.399

	true $\leq 50K$	true $> 50K$	true $\geq 50$	class precision
pred. $\leq 50K$	4470	679	1	86.80%
pred. $> 50K$	376	922	0	71.03%
pred. $\geq 50$	0	0	0	0.00%
class recall	92.24%	57.58%	0.00%	

**Gambar 4.1 Hasil Akurasi Neural Network**

Nilai akurasi yang didapatkan dari hasil prediksi perhitungan menggunakan algoritma Neural Network terhadap data pendapatan rumah tangga sesuai dengan gambar 4.1. Dengan perhitungan akurasi sebagai berikut:

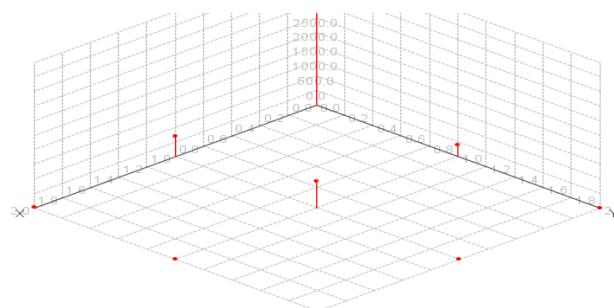
$$\text{Accuracy} = \frac{4470 + 922}{4470 + 679 + 376 + 922} = 0.83$$

$$\text{Precision} = \frac{922}{376 + 922} = 0.71$$

$$\text{Recall} = \frac{922}{679 + 922} = 0.57$$

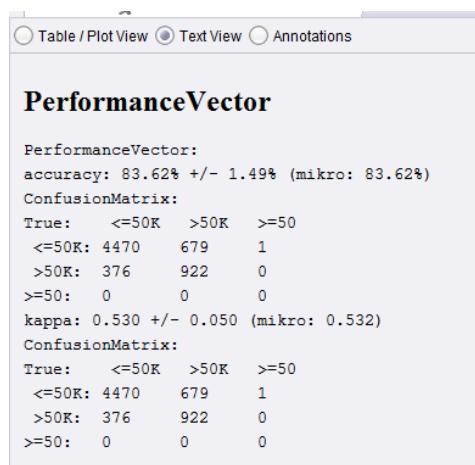
$$F - \text{Measure} = \frac{2 * 0.57 * 0.71}{0.57 + 0.71} = 0.63$$

Selanjutnya akan didapatkan hasil dari confusion matriks yaitu pada gambar 4.2. sebagai berikut :



**Gambar 4.2 Hasil Confusion matrix pada akurasi 83.62% dengan Rapid Miner**

Hasil Confusion Matrix pada gambar 4.2 dari nilai akurasi Neural network sebesar 83.62% menunjukan bahwa nilai output berupa nilai threshold untuk pendapatan kurang dari sama dengan \$50.000 sebesar -3.293, dan untuk output pendapatan yang lebih besar dari \$50.000 nilai threshold sebesar 3.293 sedangkan untuk output pendapatan yang lebih besar sama dengan \$50.000 nilai threshold sebesar -5.399.



**Gambar 4.3. hasil Performance Vector Neural Network pada data pendapatan rumah tangga dengan Rapid Miner**

Gambar 4.3. menunjukkan *performance vector* dari data pendapatan rumah tangga menggunakan algoritma neural network yang menunjukkan nilai akurasi sebesar 83.62% serta penjabaran nilai untuk confusion matrix.

#### 4. Kesimpulan dan Saran

Penelitian ini dilakukan pengujian model dengan menggunakan neural network yang akan menghasilkan nilai akurasi pada data pendapatan rumah tangga dibeberapa Negara didunia sebesar 83.62%, dengan demikian dapat dipastikan neural network dapat memprediksi data pada pengolahan dataset pendapatan rumah tangga yang diambil dari UCI dataset pada Data sensus pendapatan yang dilakukan oleh Ronny Kohavi and Barry Becker pada sensu Beureu. Akan tetapi dikarenakan neural network masih memiliki kekurangan yaitu terjadinya overgeneralisasi pada saat penginputan data dalam jumlah yang besar maka penulis menyarankan untuk meningkatkan nilai akurasi yang ada dengan algoritma yang dapat mendukung peningkatan akurasi yang ada di Neural Network seperti menggunakan Genetik Algoritm, Feature selection atau algoritma lainnya yang dapat mensupport algoritma dari Neural Network itu sendiri.

#### Referensi

- Gorunescu, Florin. (2011). *Data Mining: Concepts, Models and Techniques*. Verlag Berlin Heidelberg, Springer. Jerman.
- Guillet, Fabrice. Hamilton, Howard J. (2007). *Quality Measures in Data Mining*. Verlag Berlin Heidelberg, Springer. Jerman.
- Han,J& Kamber, Micheline. (2007). *Data Mining Concepts, Models and Techniques*. Second Edition, Morgan Kaufmann Publisher. Elsevier.
- Heaton, Jeff. (2010). *Programming Neural Networks With Encog 2 In Java*. Heaton Research.Inc, USA.
- Larose, D. (2005). *Discovering Knowledge in Data*. New Jersey, John Willey & Sons.Inc.
- Liao, Warren. T. & Triantaphyllou.Evangelos. (2007). *Recent Advances in Data Mining of Enterprise Data: Algorithms and Applications*. Series: Computer and Operation Research. 6. 190.
- Lim TS, Loh WY, Shih YS.(1999). A comparison of prediction accuracy, complexity, and training time of thirty-three old and new classification algorithms. Kluwer Academic Publishers: Boston.

- Maimon, Oded& Rokach, Lior. (2010). Data Mining and Knowledge Discovery Handbook, Springer, New York.
- Mihov, Valentin. (2015). Adult Income Data Set Analysis with IPython. Sofia University, Bulgaria.
- Min, Hui Tsai, et al.(2010). Profiling U.S. Household Income. [https://faculty.biu.ac.il/~yahavi1/Projects/C\\_P2010T1\\_rep.pdf](https://faculty.biu.ac.il/~yahavi1/Projects/C_P2010T1_rep.pdf).
- Myatt, Glenn J. (2007). Making sense of data : A Practical Guide to Exploratory data analysis and Data Mining. John Wiley & Sons Inc, New Jersey.
- Shukla, Anupam. Tiwari, Ritu. & Kala, Rahul. (2010). Real Life Application of Soft Computing. New York: Taylor and Francis Groups, LLC.
- Siang, Jong Jek (2009). Jaringan Syaraf Tiruan dan Pemrogramannya menggunakan MATLAB. Penerbit Andi. Yogjakarta.
- Topiwalla, Mohammed. (2013). Machine Learning on UCI Adult data set using various classifier algorithms and scaling up the accuracy using extreme gradient boosting. University of SP Jain School of Global Management.
- Vercellis,C. (2009). Business Intelligence: Data Mining and Optimization for Decision Making. Wiley.
- Witten,I. Frank, E., & Hall. (2011). Data Mining: Practical Machine Learning and tools. Morgan Kaufmann Publisher, Burlington.