

Analisa Kualitas Auditor Di Kantor Jasa Akuntansi Menggunakan Multi Layer Perceptron

Muhammad Mizan Siregar^{a1}, B. Herawan Hayadi^{b2}

(Center, Arial 10, First name Middle name Last name)

^{a,b}Ilmu Komputer, Universitas Potensi Utama

Jl. KL. Yos Sudarso Km. 6,5 No. 3-A, Medan, Sumatera Utara, Indonesia

[1mizan.siregar1@gmail.com](mailto:mizan.siregar1@gmail.com) (Corresponding author)

[2b.herawan.hayadi@gmail.com](mailto:b.herawan.hayadi@gmail.com)

Abstrak

Praktek audit pada umumnya dil-akukan oleh auditor yang bergabung da-lam sebuah or-ganisasi rekanan yang berisi auditor senior dan auditor junior. Kualitas audit ini pada umumnya dinilai dari kemampuan auditor dalam menemukan kesalahan dalam laporan keuangan auditee dan melaporkan temuannya tersebut. Penelitian ini membandingkan hasil klasifikasi kualitas auditor pada Kantor Jasa Akuntansi (KJA) Azhar Maksum & Rekan antara model klasifikasi multi layer perceptron yang menggunakan fungsi aktivasi ReLu, Tanh dan Sigmoid. Evaluasi diukur menggunakan k-fold cross validation dengan variasi nilai K sebesar 5, dan 10 untuk mengukur accuracy, F1, precision dan recall. Hasil yang diperoleh dari rata-rata nilai cross validation tersebut adalah fungsi aktivasi ReLu merupakan fungsi aktivasi yang terbaik untuk digunakan dalam model klasifikasi kualitas auditor KJA Azhar Maksum & Rekan, terlihat dari rata-rata nilai accuracy sebesar 82.7%, rata-rata nilai F1 sebesar 83.4%, rata-rata nilai precision sebesar 88.9% dan rata-rata nilai recall sebesar 82.7%. Serta, fungsi aktivasi Sigmoid merupakan fungsi aktivasi yang ter-buruk untuk digunakan dalam model klasifikasi kualitas auditor KJA Azhar Maksum & Rekan, terlihat dari rata-rata nilai accuracy sebesar 69.2%, rata-rata nilai F1 sebesar 56.6%, rata-rata nilai precision sebesar 47.9% dan rata-rata nilai recall sebesar 69.2%.

Kata Kunci: Fungsi Aktivasi Tanh, Fungsi Aktivasi Relu, Multi Layer Perceptron, Klasifi-Kasi, Kualitas Auditor

Abstract

Auditing practices are generally carried out by auditors who join a partner organization consisting of senior auditors and junior auditors. The quality of this audit is generally as-sessed from the ability of the auditor to find errors in the auditee's financial statements and report their findings. This study compares the results of the classification of auditor quality at the Accounting Services Office (KJA) Azhar Maksum & Partners between the multi-layer perceptron classification model that uses the ReLu, Tanh and Sigmoid activa-tion functions. Evaluation was measured using k-fold cross validation with variations in K values of 5 and 10 to measure accuracy, F1, precision and recall. The results obtained from the average cross validation value are that the ReLu activation function is the best activation function to be used in the quality classification model of KJA Azhar Maksum & Partners auditors, it can be seen from the average accuracy value of 82.7%, the average F1 value of 83.4%, the average precision value is 88.9% and the average recall value is 82.7%. Also, the Sigmoid activation function is the worst activation function to be used in the quality classification model of KJA Azhar Maksum & Partners auditors, it can be seen from the average accuracy value of 69.2%, the average F1 value of 56.6%, the average precision value of 47.9 % and the average recall value is 69.2%.

Keywords: Auditor Quality, Classification, Multi Layer Perceptron, Tanh Activation Func-Tion, Relu Activation Function

1. Pendahuluan

Kecenderungan perusahaan untuk menyampaikan informasi yang baik saja terkait dengan pelaporan keuangannya menyebabkan dibutuhkan auditor untuk mengevaluasi dan menyampaikan informasi keuangan perusahaan tersebut secara akurat, berintegritas dan independen [1].

Praktek audit pada umumnya dilakukan oleh auditor yang bergabung dalam sebuah organisasi rekanan yang berisi auditor senior dan auditor junior. Sering kali terjadi tekanan terhadap auditor yang lebih junior dari auditor yang lebih senior yang disebut dengan tekanan kepatuhan (*obedience pressure*). Tekanan ini bisa bersifat disfungsional, yang mana lebih mengarah untuk mendapatkan evaluasi yang lebih baik dari atasan atau senior [2]. Kemampuan auditor untuk beradaptasi terhadap lingkungan kerjanya agar dapat meningkatkan kemampuannya dalam menilai hasil akhir audit. Dalam hal ini, motivasi merupakan salah satu hal yang mempengaruhi kemampuan beradaptasi auditor tersebut, baik itu motivasi yang bersifat internal maupun yang bersifat eksternal [3].

Kantor Jasa Akuntansi (KJA), sebagai salah satu jenis lembaga akuntan publik sangat dipengaruhi oleh reputasi auditor yang bekerja di dalamnya, maka tingkat kepercayaan auditee terhadap kualitas hasil audit KJA tersebut akan semakin tinggi. Kualitas audit ini pada umumnya dinilai dari kemampuan auditor dalam menemukan kesalahan dalam laporan keuangan auditee dan melaporkan temuannya tersebut [4].

Data mining, proses ekstraksi informasi dan pola yang berguna dari data yang sangat besar, dapat digunakan untuk menemukan pengetahuan, menambang pengetahuan dari data, dan mengekstraksi pengetahuan atau menganalisis pola di dalam data. Klasifikasi merupakan salah satu teknik data mining yang paling umum diterapkan, yang menggunakan serangkaian contoh yang telah diklasifikasikan sebelumnya untuk mengembangkan model yang dapat mengklasifikasikan populasi secara luas. Proses klasifikasi melibatkan pembelajaran (*learning*) dan klasifikasi. Dalam proses pembelajaran, data latih dianalisis dengan algoritma klasifikasi. Dalam data uji, klasifikasi digunakan untuk memperkirakan keakuratan aturan klasifikasi. Jika akurasi dapat diterima, aturan dapat diterapkan pada tupel data baru [5].

Machine learning, salah satu cabang dari data mining, menggunakan metode data mining, namun dengan tujuan yang berbeda, yaitu untuk meningkatkan akurasi pembelajaran. Machine learning dapat dikategorikan dalam dua kategori yaitu *shallow learning* dan *deep learning*. *Shallow learning* pada dasarnya menggunakan jaringan saraf dengan lapisan tunggal, sedangkan *deep learning* menggunakan jaringan saraf dengan lebih dari satu lapisan tersembunyi [6].

Artificial neural network merupakan salah satu jenis *shallow learning* yang hanya menggunakan satu lapisan dalam mengklasifikasikan data. Metode ini sering digunakan untuk memecahkan masalah prediksi maupun klasifikasi karena akurasi yang cukup baik dan mampu mengolah data yang bersifat non-linear [7]–[9].

Dalam pengembangannya, artificial neural network berkembang menjadi *deep learning* yang menggunakan lebih dari satu lapisan dalam proses klasifikasinya. Lapisan yang ditambahkan pada *hidden layer* ini bertujuan untuk mengolah kembali hasil yang mengalami *over-fitting*, sehingga tingkat kesalahan klasifikasi dapat diminimalisir [10], [11].

Salah satu algoritma *deep learning* yang sudah banyak digunakan dalam penelitian klasifikasi adalah *multi layer perceptron* (MLP). MLP memiliki kelebihan seperti mampu mengadaptasikan dirinya dengan data, dapat memperkirakan hubungan antar keanggotaan kelas dengan atribut dari objek, lebih reliabel terhadap noise dalam data, dan mampu menghitung nilai probabilitas posterior, yang merupakan dasar untuk membangun aturan klasifikasi dan analisis statistika. MLP memiliki setidaknya tiga *hidden layer* dalam arsitekturnya, sehingga masing-masing neuron dapat melakukan perhitungan ulang untuk mengatasi kemungkinan *overfitting* yang terjadi [12]–[14].

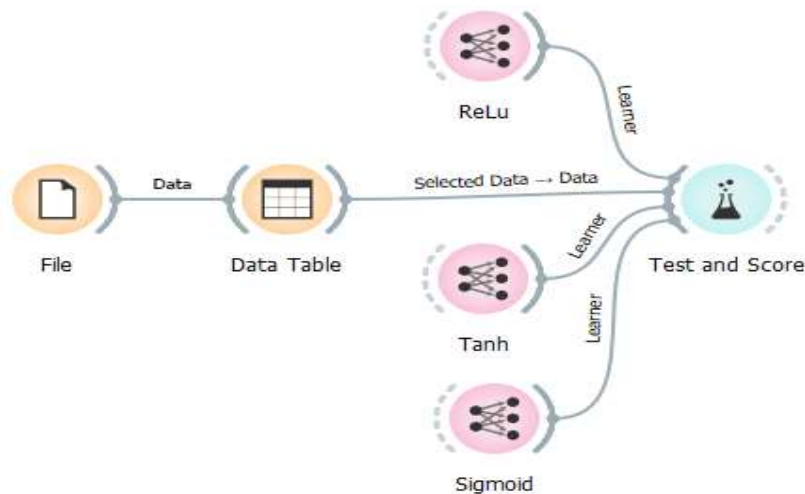
Beberapa penelitian yang menggunakan algoritma MLP telah menunjukkan performa yang baik dari algoritma ini, seperti penelitian mengenai analisis sentimen presiden Jokowi dengan tingkat akurasi 90%, penelitian mengenai klasifikasi citra dengan rata-rata akurasi 76,49%, dan

penelitian mengenai klasifikasi kelas rumah sakit di DKI Jakarta dengan tingkat akurasi 92,64% [15]–[17].

Penelitian ini mengklasifikasi kualitas auditor di Kantor Jasa Akuntansi (KJA) Azhar Maksu & Rekan-menggunakan algoritma multi layer per-ceptra. Proses klasifikasi menggunakan variasi fungsi aktivasi yang berbeda, seperti ReLu, Tanh, dan Sigmoid dengan fungsi optimasi yang digunakan adalah fungsi optimasi Adam. Hasil klasifikasi menggunakan masing-masing variasi fungsi aktivasi ini kemudian dievaluasi menggunakan cross validation untuk memperoleh nilai accuracy, F1, precision, dan recall. Berdasarkan nilai-nilai yang diperoleh menggunakan cross validation dengan jumlah fold sebesar 5, 10, dan 20, dihitung rata-rata masing-masing nilai untuk melihat fungsi aktivasi mana yang lebih baik untuk digunakan sebagai model klasifikasi.

2. Metode Penelitian

Penelitian ini membandingkan fungsi aktivasi multi layer perceptron, yang terdiri dari fungsi aktivasi ReLu dan fungsi aktivasi Tanh, pada dataset auditor KJA menggunakan aplikasi Orange 3.30, dengan bentuk model seperti terlihat pada Gambar 1.



Gambar 1. Model Klasifikasi

Dataset yang digunakan adalah data auditor KJA Azhar Maksu & Rekan dengan jumlah 52 data. Data ini terdiri dari 4 kelas fitur seperti tingkat kepatuhan, tingkat kemampuan, tingkat pengalaman dan tingkat pengetahuan serta 1 kelas target yaitu audit judgement. Tabel 1 menunjukkan 10 sampel dataset yang digunakan.

Tabel 1. Sampel Dataset

X1	X2	X3	X4	Y
4	3	4	4	Baik
1	1	1	1	Buruk
3	3	3	3	Baik
2	3	1	2	Baik
3	4	3	3	Baik
2	1	1	2	Buruk
4	4	3	4	Baik
1	2	2	1	Baik
2	4	3	2	Baik
2	2	2	2	Baik

Dataset ini kemudian dinormal-isasi, sehingga menghasilkan dua nilai “baik” dan “buruk” untuk masing-masing fitur. Tabel 2 menunjukkan hasil normal-isasi 10 sampel dataset yang digunakan.

Tabel 2. Normalisasi Dataset

X1	X2	X3	X4	Y
Baik	Baik	Baik	Baik	Baik
Buruk	Buruk	Buruk	Buruk	Buruk
Baik	Baik	Baik	Baik	Baik
Buruk	Baik	Buruk	Buruk	Baik
Baik	Baik	Baik	Baik	Baik
Buruk	Buruk	Buruk	Buruk	Buruk
Baik	Baik	Baik	Baik	Baik
Buruk	Buruk	Buruk	Buruk	Baik
Buruk	Baik	Baik	Buruk	Baik
Buruk	Buruk	Buruk	Buruk	Baik

Proses klasifikasi kualitas auditor dilakukan dengan menggunakan parameter hidden layer, jumlah neuron per hidden layer, jumlah fold untuk cross validation, fungsi aktivasi dan algoritma optimasi seperti terlihat pada Tabel 3.

Tabel 3. Parameter Klasifikasi

Parameter	Nilai
<i>Hidden layer</i>	3
<i>Neuron per hidden layer</i>	10
<i>k-fold cross validation</i>	5, dan 10
Fungsi Aktivasi	ReLu, Tanh dan Sigmoid
Fungsi Optimasi	Adam

Evaluasi klasifikasi diukur melalui nilai *classification accuracy*, *F1*, *precision* dan *recall* yang dihitung dengan menggunakan persamaan (1) sampai persamaan (4) berikut [18]:

$$Accuracy = \frac{TP+}{TP+TN+FP+FN} \tag{1}$$

$$Precision = \frac{TP}{TP+FP} \tag{2}$$

$$Recall = \frac{TP}{TP+FN} \tag{3}$$

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision+Recall} \tag{4}$$

Keterangan:

TP = *True Positive*.

TN = *True Negative*.

FP = *False Positive*.

FN = *False Negative*.

3. Hasil dan Pembahasan

Masing-masing parameter klasifikasi pada Tabel 2 diinputkan ke dalam model klasifikasi pada Gambar 1 dengan jumlah maksimum epoch sebanyak 50.

Diperoleh nilai accuracy, F1, precision dan recall dari hasil klasifikasi MLP menggunakan variasi fungsi aktivasi ReLu dan Adam menggunakan 5-Fold, 10-Fold, dan 20-Fold Cross Validation seperti terlihat pada Tabel 4.

Tabel 4. Hasil Cross Validation

Fungsi Aktivasi	Fold	Cross Validation			
		Accuracy	F1	Precision	Recall
ReLu	5	82.7	83.4	88.9	82.7
	10	82.7	83.4	88.9	82.7
	Rata-rata	82.7	83.4	88.9	82.7
Tanh	5	80.8	81.5	88.2	80.8
	10	80.8	81.5	88.2	80.8
	Rata-rata	80.8	81.5	88.2	80.8
Sigmoid	5	69.2	56.6	47.9	69.2
	10	69.2	56.6	47.9	69.2
	Rata-rata	69.2	56.6	47.9	69.2

Dari Tabel 3, terlihat bahwa untuk fungsi aktivasi ReLu, pada evaluasi 5-fold cross validation menghasilkan nilai accuracy sebesar 82.7%, nilai F1 sebesar 83.4%, nilai precision sebesar 88.9%, dan nilai recall sebesar 82.7%. Pada evaluasi 10-fold cross validation, fungsi aktivasi ReLu menghasilkan nilai accuracy sebesar 82.7%, nilai F1 sebesar 83.4%, nilai precision sebesar 88.9%, dan nilai recall sebesar 82.7%. Dari seluruh evaluasi cross validation ini, diperoleh nilai rata-rata accuracy sebesar 82.7%, nilai F1 sebesar 83.4%, nilai precision sebesar 88.9%, dan nilai recall sebesar 82.7%.

Untuk fungsi aktivasi Tanh, pada evaluasi 5-fold cross validation menghasilkan nilai accuracy sebesar 80.8%, nilai F1 sebesar 81.5%, nilai precision sebesar 88.2%, dan nilai recall sebesar 80.8%. Pada evaluasi 10-fold cross validation, fungsi aktivasi Tanh menghasilkan nilai accuracy sebesar 80.8%, nilai F1 sebesar 81.5%, nilai precision sebesar 88.2%, dan nilai recall sebesar 80.8%. Dari seluruh evaluasi cross validation ini, diperoleh nilai rata-rata accuracy sebesar 80.8%, nilai F1 sebesar 81.5%, nilai precision sebesar 88.2%, dan nilai recall sebesar 80.8%.

Untuk fungsi aktivasi Sigmoid, pada evaluasi 5-fold cross validation menghasilkan nilai accuracy sebesar 69.2%, nilai F1 sebesar 56.6%, nilai precision sebesar 47.9%, dan nilai recall sebesar 69.2%. Pada evaluasi 10-fold cross validation, fungsi aktivasi Sigmoid menghasilkan nilai accuracy sebesar 69.2%, nilai F1 sebesar 56.6%, nilai precision sebesar 47.9%, dan nilai recall sebesar 69.2%. Dari seluruh evaluasi cross validation ini, diperoleh nilai rata-rata accuracy sebesar 69.2%, nilai F1 sebesar 56.6%, nilai precision sebesar 47.9%, dan nilai recall sebesar 69.2%.

4. Kesimpulan

Dari hasil evaluasi klasifikasi kualitas auditor di KJA Azhar Maksu & Rekan menggunakan fungsi aktivasi ReLu, Tanh, dan Sigmoid yang diterapkan pada algoritma multi layer perceptron ini, dapat disimpulkan bahwa fungsi aktivasi ReLu merupakan fungsi aktivasi yang terbaik untuk digunakan dalam model klasifikasi kualitas auditor KJA Azhar Maksu & Rekan, terlihat dari nilai accuracy, F1, precision dan recall yang dihasilkannya lebih tinggi dari hasil klasifikasi fungsi aktifasi Tanh dan Sigmoid. Serta, fungsi aktivasi Sigmoid merupakan fungsi aktivasi yang terburuk untuk digunakan dalam model klasifikasi kualitas auditor KJA Azhar Maksu & Rekan, dibandingkan fungsi aktivasi ReLu dan Tanh.

Daftar Pustaka

- [1] W. A. Ginting and Munawarah, "Analisis Faktor-Faktor Yang Mempengaruhi Audit Judgement," *ATESTASI J. Ilm. Akunt. J. Ilm. Akunt.*, vol. 2, no. 1, pp. 31–40, 2019, doi: <https://doi.org/10.33096/atestasi.v2i1.124>.
- [2] D. Nasution and R. Östermark, "The impact of social pressures, locus of control, and professional commitment on auditors' judgment: Indonesian evidence," *Asian Rev. Account.*, vol. 20, no. 2, pp. 163–178, 2012, doi: 10.1108/13217341211242204.
- [3] T. M. Iskandar, R. N. Sari, Z. Mohd-Sanusi, and R. Anugerah, "Enhancing auditors' performance: The importance of motivational factors and the mediation effect of effort," *Manag. Audit. J.*, vol. 27, no. 5, pp. 462–476, 2012, doi: 10.1108/02686901211227959.
- [4] P. Kurnia and N. F. Mella, "Opini Audit Going Concern : Kajian Berdasarkan Kualitas Audit , Kondisi Keuangan , Audit Tenure , Ukuran Perusahaan , Pertumbuhan Perusahaan dan Opini Audit Tahun Sebelumnya pada Perusahaan yang Mengalami Financial Distress pada Perusahaan Manufaktur (Stu)," *J. Ris. Akunt. dan Keuang.*, vol. 6, no. 1, pp. 105–122, 2018.
- [5] N. Dey, A. S. Ashour, and G. N. Nguyen, "Deep learning for multimedia content analysis," *Min. Multimed. Doc.*, vol. 1, no. 4, pp. 193–203, 2017, doi: 10.1201/b21638.
- [6] A. Chahal and P. Gulia, "Machine learning and deep learning," *Int. J. Innov. Technol. Explor. Eng.*, vol. 8, no. 12, pp. 4910–4914, 2019, doi: 10.35940/ijitee.L3550.1081219.
- [7] B. Yanto, J. Jufri, A. Lubis, B. H. Hayadi, and E. Armita, NST, "Klarifikasi Kematangan Buah Nanas Dengan Ruang Warna Hue Saturation Intensity (Hsi)," *INOVTEK Polbeng - Seri Inform.*, vol. 6, no. 1, p. 135, 2021, doi: 10.35314/isi.v6i1.1882.
- [8] A. Wanto *et al.*, "Forecasting the Export and Import Volume of Crude Oil, Oil Products and Gas Using ANN," *J. Phys. Conf. Ser.*, vol. 1255, no. 1, 2019, doi: 10.1088/1742-6596/1255/1/012016.
- [9] B. H. Hayadi, J.-M. Kim, K. Hulliyah, and H. T. Sukmana, "Predicting Airline Passenger Satisfaction with Classification Algorithms," *IJIS Int. J. Informatics Inf. Syst.*, vol. 4, no. 1, pp. 82–94, 2021, doi: 10.47738/ijis.v4i1.80.
- [10] B. Yanto, B. -, J. -, and B. H. Hayadi, "Identifikasi Pola Aksara Arab Melayu Dengan Jaringan Syaraf Tiruan Convolutional Neural Network (Cnn)," *JSAI (Journal Sci. Appl. Informatics)*, vol. 3, no. 3, pp. 106–114, 2020, doi: 10.36085/jsai.v3i3.1151.
- [11] B. Yanto, L. Fimawahib, A. Supriyanto, B. H. Hayadi, and R. R. Pratama, "Klasifikasi Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecerahan Warna dengan Metode Deep Learning Convolutional Neural Network," *INOVTEK Polbeng - Seri Inform.*, vol. 6, no. 2, p. 259, 2021, doi: 10.35314/isi.v6i2.2104.
- [12] M. S. Wibawa and I. M. D. Maysanjaya, "Multi Layer Perceptron Dan Principal Component Analysis Untuk Diagnosa Kanker Payudara," *J. Nas. Pendidik. Tek. Inform.*, vol. 7, no. 1, p. 90, 2018, doi: 10.23887/janapati.v7i1.12909.
- [13] M. S. Rini, "Kajian kemampuan metode neural network untuk klasifikasi penutup lahan dengan menggunakan Citra Landsat-8 OLI (kasus di Kota Yogyakarta dan sekitarnya)," *Geomedia Maj. Ilm. dan Inf. Kegeografian*, vol. 16, no. 1, pp. 1–12, 2018, doi: 10.21831/gm.v16i1.20974.
- [14] K. I. Ahamed and S. Akthar, "A Study on Neural Network Architectures," vol. 7, no. 9, pp. 1–7, 2016, [Online]. Available:

- <https://iiste.org/Journals/index.php/CEIS/article/view/32857>.
- [15] N. Munasatya and S. Novianto, "Natural Language Processing untuk Sentimen Analisis Presiden Jokowi Menggunakan Multi Layer Perceptron," *Techno.Com*, vol. 19, no. 3, pp. 237–244, Aug. 2020, doi: 10.33633/tc.v19i3.3630.
- [16] A. Peryanto, A. Yudhana, and R. Umar, "Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation," *J. Appl. Informatics Comput.*, vol. 4, no. 1, pp. 45–51, 2020, doi: 10.30871/jaic.v4i1.2017.
- [17] A. F. Hardiyanti and D. Fitriana, "Perbandingan Algoritma C4.5 dan Multilayer Perceptron untuk Klasifikasi Kelas Rumah Sakit di DKI Jakarta," *J. Telekomun. dan Komput.*, vol. 11, no. 3, p. 198, 2021, doi: 10.22441/incomtech.v11i3.10632.
- [18] H. Dalianis, "Evaluation Metrics and Evaluation," *Clin. Text Min.*, no. 1967, pp. 45–53, 2018, doi: 10.1007/978-3-319-78503-5_6.