

Klasifikasi Faktor Yang Mempengaruhi *Asfiksia* Menggunakan Multilayer Perceptron Neural Network

Finki Dona Marleny¹⁾, Liliana Swastina²⁾, Bambang Lareno³⁾, Mambang⁴⁾

^{1,2,3}Teknik Informatika, STMIK Indonesia Banjarmasin

Jln. Pangeran Hidayatullah – Banua Anyar. Telp.(0511) 4315530. Banjarmasin

⁴Kebidanan, STIKES Sari Mulia, Banjarmasin

Jln. Pramuka No. 02 Banjarmasin

e-mail: [1finkidona@gmail.com](mailto:finkidona@gmail.com), [2lilisera@gmail.com](mailto:lilisera@gmail.com), [3blareno@gmail.com](mailto:blareno@gmail.com), [4mhgche@yahoo.co.id](mailto:mhgche@yahoo.co.id)

Abstrak

Asfiksia merupakan gejala yang disebabkan oleh cedera pada sistem saraf pusat, yang meliputi otak dan sumsum tulang belakang. Asfiksia dapat dipengaruhi oleh beberapa faktor secara langsung atau tidak yaitu pada ibu, bayi dan saat persalinan. Makalah ini mengusulkan klasifikasi menggunakan algoritma multilayer perceptron untuk pengklasifikasian faktor yang mempengaruhi kejadian Asfiksia. Pada penelitian ini ada 13 faktor yang digunakan untuk mendukung metode MLP Neural Network dalam mengklasifikasi faktor yang mempengaruhi asfiksia, sehingga didapatkan tingkatan pada kejadian asfiksia yaitu asfiksia sedang dan asfiksia berat. Hasil training dan testing, pada hasil training MLPNN dengan menggunakan fungsi aktivasi output layer identitas hanya dapat menghasilkan akurasi klasifikasi 84,3% dan 81,5%. Untuk pengujian didapatkan akurasi 87,7% dan 84,4%. Sedangkan untuk hasil training MLP dengan menggunakan fungsi aktivasi output layer sigmoid menghasilkan akurasi 94,5% dan 91,6%. Untuk hasil pengujian didapatkan akurasi lebih baik yaitu 90,5% dan 89,0%.

Kata kunci: *asfiksia, multilayer-perceptron, klasifikasi, fungsi-aktivasi*

1. Pendahuluan

Kejadian *asfiksia neonatorum* adalah suatu keadaan dimana bayi tidak dapat bernafas secara spontan dan teratur setelah lahir. Hal ini disebabkan oleh hipoksia janin dalam uterus dan hipoksia ini berhubungan dengan faktor-faktor yang timbul dalam kehamilan, persalinan, atau segera setelah bayi lahir [1]. Asfiksia neonatorum terjadi karena adanya gangguan pertukaran gas serta transport O² dari ibu ke janin sehingga terdapat gangguan dalam persediaan O² dan dalam menghilangkan CO². Pencegahan awal akan terjadinya *asfiksia neonatorum* merupakan satu kesatuan integral pada praktik kebidanan yang efektif. Pengkajian dimulai dari saat pendaftaran di klinik untuk mendapatkan informasi selama masa kehamilan dan pemantauan dilakukan selama masa persalinan. Bidan harus mewaspadai resiko *asfiksia* pada janin yang bermasalah pada periode *antenatal* dalam kehamilan yang memiliki komplikasi seperti janin dengan gangguan *intrauterine*, *insufisiensi plasenta* atau *toksemia*. Tetapi pada intinya tidak mungkin memprediksikan dengan pasti bahwa seorang bayi akan dilahirkan dengan kondisi yang baik, karena pada kelahiran resiko rendah juga dapat mengalami *asfiksia* [2].

Asfiksia dapat dipengaruhi oleh beberapa faktor secara langsung atau tidak, diantaranya faktor yang mempengaruhi secara langsung adalah faktor ibu yaitu yang berkaitan dengan kondisi ibu pada masa kehamilan dan proses persalinan seperti hipoksia ibu, usia ibu kurang dari 20 tahun atau lebih dari 35 tahun, paritas, penyakit yang diderita ibu seperti hipertensi, hipotensi, gangguan kontraksi uterus dan lain-lain[3]. Asfiksia merupakan gejala yang disebabkan oleh cedera pada sistem saraf pusat, yang meliputi otak dan sumsum tulang belakang [4][5]. Bahkan ada studi yang menunjukkan korelasi yang kuat antara tangisan bayi saat dilahirkan dan penyakit[6]. Kejadian asfiksia memiliki pola yang berbeda, yang dapat dikenali dengan pola pengklasifikasi seperti jaringan syaraf tiruan (JST) salah satunya menggunakan multilayer perceptron (MLP).

Pada penelitian Azlee Zabidi [7] yang menggunakan sinyal tangisan bayi untuk pola pengklasifikasian dengan menggunakan metode multilayer perceptron menghasilkan percobaan dengan *different vektor* fitur input yang dilakukan untuk perbaikan untuk memasukkan peringkat vektor fitur dan juga untuk menentukan aturan koefisien seperti persentase koefisien. Selain itu, klasifikasi MLP dibandingkan dengan hasil dari pemilihan langsung, menggabungkan kombinasi vektor fitur input dalam

struktur jaringan, nomor dan jumlah koefisien. Akurasi tertinggi yang dilaporkan penelitian Azlee mencapai 94% dengan nomor pilihan koefisien pada 30% dari filter dan dari 15 hidden nodes.

MLP secara khusus digunakan untuk masalah non-linear yang membutuhkan lebih dari satu lapisan tersembunyi di antara input dan output layer. Model MLP dengan menyebarkan kesalahan secara *backward* untuk meningkatkan kekuatan prediksi dari model dan dengan menambahkan jumlah yang tepat dari *hidden* neuron di antara input dan output lapisan [8]. Selanjutnya Sujata [9] menggunakan MLP untuk menganalisis kinerja algoritma yang pada empat dataset dalam pengklasifikasian dataset kanker untuk menghitung presisi, TP / FP tingkat dan ROC. Algoritma MLP menyeleksi fitur yang efisien untuk dataset dimensi tinggi guna mengurangi ukuran dimensi dataset, waktu pembentukan model dan meningkatkan akurasi klasifikasi.

Penelitian ini bertujuan membuat sebuah model yang dapat digunakan untuk mengklasifikasi faktor yang mempengaruhi asfiksia sehingga didapatkan tingkatan pada kejadian asfiksia yaitu asfiksia sedang dan asfiksia berat. Data yang digunakan dalam penelitian ini adalah data sekunder yakni data yang diperoleh dari rekam medik (register bayi baru lahir dan ibu bersalin) yang mencakup seluruh bayi baru lahir di ruang bayi dan ruang bersalin di RSUD Dr. H. Moch Ansari Saleh Banjarmasin.

2. Metode Penelitian

2.1 Pengumpulan dan pengolahan data awal

Penelitian ini menggunakan data rekam medik (register bayi baru lahir dan ibu bersalin) yang mencakup seluruh bayi baru lahir di ruang bayi dan ruang bersalin di RSUD Dr. H. Moch Ansari Saleh Banjarmasin tahun 2013.

Data dibagi menjadi beberapa bagian dari data ibu, bayi dan penyulit persalinan yaitu:

- a. Data Ibu
 - Umur Ibu = 20-35 tahun dan lebih dari 35 tahun
 - Paritas = paritas aman yaitu jumlah anak hidup yang dilahirkan ibu paritas 2-3, tidak aman yaitu paritas 1 dan lebih dari 3 [10].
 - Riwayat penyakit = Anemia, asma, hipertensi, Diabetes Melitus(DM), tidak ada
 - Keadaan Plasenta = Plasenta Previa, Solusio Plasenta, Retensio dan Lengkap
- b. Data Bayi
 - Prematur = ya, tidak
 - Berat Badan = Normal (>2500 gr), BBLR (1500-2500 gr), BBLSR (1000-1500 gr), BBLER (<1000 gr).
- c. Penyulit Persalinan
 - Kehamilan ganda = ya, tidak
 - Letak sungsang = ya, tidak
 - Kala II Lama = ya, tidak
 - Distosia = ya, tidak
 - Cepalo PelvicDisoroportion* (CPD) = ya, tidak
 - Ketuban Pecah Dini (KPD) = ya, tidak

Berikut contoh 15 baris data dari 245 baris data yang akan diolah menggunakan klasifikasi MLP, dapat dilihat pada tabel 1.

Tabel 1. Data faktor yang mempengaruhi kejadian asfiksia

	Umur	Paritas	RiwayatPeny...	JenisPersalinan	keadaanplasenta	prematu...	beratba...	Kehamil...	Letaksur...	kalallam...	CPD	Distosia	KPD
1	20	Tidak Aman	Anemia	SC	Plasenta Previa	YA	BBLSR	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK
2	32	Aman	Asma	Pervaginam	Lengkap	YA	BBLSR	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK
3	37	Tidak Aman	Anemia	Pervaginam	Lengkap	TIDAK	BBLR	TIDAK	TIDAK	TIDAK	YA	TIDAK	TIDAK
4	21	Tidak Aman	Anemia	SC	Solusio Plasenta	TIDAK	BBLSR	YA	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK
5	34		Tidak Ada	Pervaginam	Solusio Plasenta	TIDAK	Normal	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK
6	38	Tidak Aman	Tidak Ada	Pervaginam	Lengkap	YA	BBLR	TIDAK	YA	TIDAK	TIDAK	TIDAK	TIDAK
7	35	Aman	Anemia	SC	Plasenta Previa	TIDAK	Normal	TIDAK	YA	TIDAK	TIDAK	TIDAK	TIDAK
8	22	Tidak Aman	Tidak Ada	Pervaginam	Lengkap	TIDAK	Normal	TIDAK	YA	TIDAK	TIDAK	TIDAK	TIDAK
9	34	Tidak Aman	Hipertensi	Pervaginam	Lengkap	TIDAK	Normal	TIDAK	YA	TIDAK	TIDAK	TIDAK	TIDAK
10	27	Tidak Aman	Tidak Ada	Pervaginam	Lengkap	YA	BBLR	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK
11	36	Aman	Anemia	SC	Solusio Plasenta	TIDAK	Normal	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK
12	34	Tidak Aman	Tidak Ada	Pervaginam	Lengkap	TIDAK	Normal	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK	YA
13	42	Tidak Aman	Tidak Ada	Pervaginam	Lengkap	TIDAK	Normal	YA	TIDAK	YA	TIDAK	TIDAK	TIDAK
14	35	Tidak Aman	Anemia	SC	Plasenta Previa	TIDAK	Normal	TIDAK	TIDAK	YA	TIDAK	TIDAK	TIDAK
15	21	Tidak Aman	Hipertensi	Pervaginam	Lengkap	YA	BBLER	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK	TIDAK

2.2 Model yang diusulkan

Model yang diusulkan menggunakan metode klasifikasi algoritma MLP Neural Network, yang akan dianalisa dengan SPSS.

2.2.1 Multilayer Perceptron (MLP)

Perceptron yang memiliki satu lapisan bobot hanya memiliki fungsi linear perkiraan input dan tidak bisa memecahkan masalah seperti XOR, di mana diskriminan yang akan diestimasi adalah nonlinear. Demikian pula, perceptron tidak dapat digunakan untuk regresi nonlinear. Keterbatasan ini tidak berlaku untuk jaringan dengan lapisan menengah atau tersembunyi antara lapisan hidden input dan lapisan output. Jika digunakan untuk klasifikasi, multilayer seperti perceptrons MLP dapat melaksanakan diskriminan nonlinier dan, jika digunakan untuk regresi, dapat menggunakan perkiraan fungsi nonlinier input [11].

2.2.2 Fungsi Aktivasi

Beberapa fungsi aktivasi yang digunakan adalah sebagai berikut [12]:

a. Fungsi Sigmoid

$$f_{sig}(net_i) = \frac{1}{1 + e^{-2.15 \cdot net_i}} \quad (1)$$

b. Fungsi Identitas

$$f(x) = x \quad (2)$$

2.2.3 Gradient Descent with Momentum

Algoritma standard yang digunakan dalam pelatihan MLP Neural Network adalah *gradient descent with momentum*, yaitu perubahan bobot didasarkan atas gradien yang terjadi untuk pola yang dimasukkan saat itu. Modifikasi yang dapat dilakukan adalah melakukan perubahan bobot yang didasarkan atas arah gradien pola terakhir dari pola sebelumnya (disebut momentum) yang dimasukkan, jadi tidak hanya pola masukan terakhir saja yang diperhitungkan.

Penambahan momentum dimaksudkan untuk menghindari perubahan bobot yang mencolok akibat adanya data yang sangat berbeda dengan yang lain (outlier). Apabila beberapa data terakhir yang diberikan ke jaringan memiliki pola yang serupa (berarti arah gradien sudah benar), maka perubahan bobot dilakukan secara cepat. Namun, apabila data terakhir yang dimasukkan memiliki pola yang berbeda dengan pola sebelumnya, maka perubahan dilakukan secara lambat.

Dengan Penambahan momentum, bobot baru pada waktu ke (t+1) didasarkan atas bobot pada waktu t dan (t-1). Disini harus ditambahkan dua variabel baru yang mencatat besarnya momentum untuk dua iterasi terakhir. Jika μ adalah konstanta ($0 \leq \mu \leq 1$) yang menyatakan parameter momentum maka bobot baru dihitung berdasarkan persamaan :

$$w_{:,j}(t+1) = w_{:,j}(t) + \alpha \delta_j \cdot z_j + \mu(w_{:,j}(t) - w_{:,j}(t-1)) \quad (3)$$

dan

$$v_{:,i}(t+1) = v_{:,i}(t) + \alpha \delta_i \cdot x_i + \mu(v_{:,i}(t) - v_{:,i}(t-1)) \quad (4)$$

Dengan cara ini, apabila *learning rate* terlalu tinggi dan mengarah ke ketidak stabilan, maka *learning rate* akan diturunkan. Sebaliknya jika *learning rate* terlalu kecil untuk menuju konvergensi, maka *learning rate* akan dinaikkan. Dengan demikian, maka algoritma pembelajaran akan tetap terjaga pada kondisi stabil.

2.2.4 ROC Curve

Receiver Operating Characteristic (ROC) Curve adalah alat untuk mengevaluasi kinerja klasifikasi biner. Fungsinya adalah untuk menentukan ambang batas klasifikasi optimal yang memaksimalkan akurasi klasifikasi dan meminimalkan kesalahan klasifikasi. ROC kurva bergantung pada notasi sensitivitas dan spesifisitas. Nilai-nilai ini tergantung pada set data tertentu [13].

ROC kurva dibangun dengan mengukur dua nilai, yaitu dimulai dengan batas minimum dan kemudian meningkat perlahan-lahan. Kekhususan dan sensitivitas pasangan mampu membenarkan *threshold* optimal untuk melakukan klasifikasi. Kurva ROC memberikan gambaran kinerja keseluruhan tes. Ketika kurva ROC dari tes yang berbeda dibandingkan, kurva klasifikasi baik terletak dekat dengan

sudut kiri atas, sementara pengklasifikasi buruk cenderung berkumpul di dekat garis. Sensitivitas dihitung sebagai berikut:


$$Sensitivity = \frac{TP}{TP+FN} \tag{5}$$

$$Sensitivity = \frac{TN}{TN+FP} \tag{6}$$

Dimana TP, TN, FP dan FN yang benar-diklasifikasikan kasus positif, kasus negatif benar-diklasifikasikan, kasus positif salah-salah diklasifikasikan dan digolongkan kasus negatif, masing-masing. Secara teori, sensitivitas dan spesifisitas independen dalam arti bahwa adalah mungkin untuk mencapai 100% di kedua. Ambang terbaik dicapai ketika sensitivitas mendekati satu dan spesifisitas mendekati nol. Indikasi lain dari klasifikasi yang baik adalah ketika area di bawah kurva ROC (AUC) dekat 100%.

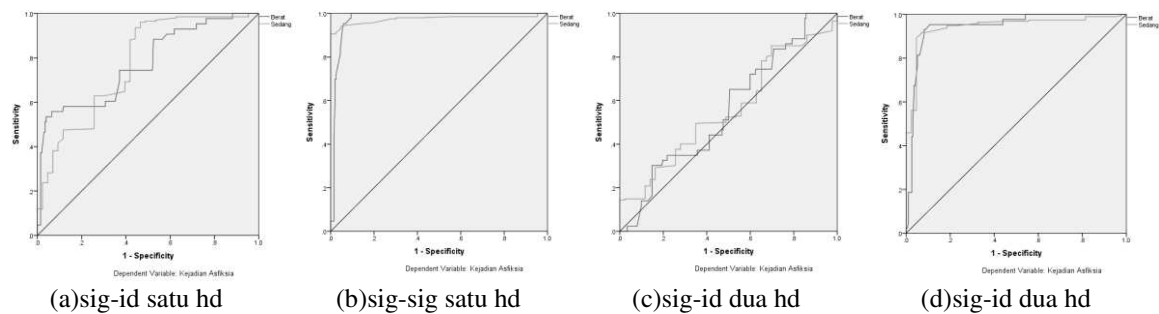
2.3. Pengujian Model

Data yang akan digunakan sebanyak 245 baris data. Sebanyak 70% digunakan untuk pelatihan dan 30% uji akurasi. Label Hasil untuk kejadian asfiksia adalah **Sedang** dan **Berat**. Pengujian model arsitektur jaringan MLP neural Network, dapat dilihat pada gambar berikut:



Gambar 1. Boxplot dari rata-rata tingkat faktor variabel *dependent*

Gambar 1 (a) dan Gambar 2 (a) merupakan hasil pengujian model menggunakan arsitektur satu hidden layer, dengan fungsi aktivasi sigmoid, sedangkan layer output menggunakan aktivasi identitas. Boxplots yang dihasilkan digunakan untuk membandingkan dataset pada setiap data pada gambar 1. (b), (c) dan (d) adalah boxplot dari tingkat rata-rata faktor variabel *dependent* sampel pelatihan dan pengujian gabungan. Paling kiri boxplot menunjukkan kasus-kasus, yang diamati, kategori **Berat**. Bagian kanan menunjukkan kasus-kasus, yang diamati, kategori **Sedang**. Ini mekanisme statistik guna penetapan fitur vektor untuk klasifikasi melalui MLP Neural Network.



Gambar 2. ROC Curve

Berdasarkan plot Kurva ROC (Gambar 2), analisis digunakan untuk menampilkan kemampuan MLP untuk mengklasifikasikan kasus positif dan negatif dengan benar. Gambar 2 menunjukkan jumlah unit tersembunyi, sensitivitas dan AUC untuk berbagai koefisien dari metode pemilihan langsung. Kurva ROC memberikan tampilan visual dari sensitivitas dengan spesifisitas untuk semua kemungkinan

klasifikasi. Gambar 2 menunjukkan empat kurva, satu untuk setiap kategori variabel target, berdasarkan pelatihan dan pengujian sample gabungan.

3. Hasil dan Pembahasan

Data dianalisa menggunakan arsitektur jaringan MLP Neural Network dengan gradient descent with momentum = 0.9 dan learning rate=0.4, menghasilkan jaringan dengan Akurasi sebagai berikut:

Tabel 2. Arsitektur jaringan Pengujian Model

Hidden Layers		Output Layer	Hasil		
Nomor Hidden Layers	Fungsi Aktivasi	Fungsi Aktivasi	Training akurasi	Testing akurasi	AUC
1	Sigmoid	Identitas	84,3%	87,7%	.773
1	Sigmoid	Sigmoid	94,5%	90,5%	.975
2	Sigmoid	Identitas	81,5%	84,4%	.558
2	Sigmoid	Sigmoid	91,6%	89,0%	.944

Pada hasil yang ditunjukkan Tabel 2, yang ditentukan berdasarkan trial and error, diperoleh jumlah optimal unit tersembunyi untuk mendapatkan akurasi terbaik. Pada hasil training MLP dengan menggunakan fungsi aktivasi output layer identitas hanya dapat menghasilkan akurasi klasifikasi 84,3% dan 81,5%. Pada hasil pengujian didapatkan akurasi 87,7% dan 84,4%. Sedangkan hasil training MLP dengan menggunakan fungsi aktivasi output layer sigmoid menghasilkan akurasi 94,5% dan 91,6%. Hasil pengujian menunjukkan akurasi pengujian terbaik, yaitu 90,5% dengan AUC .975 dan jumlah hidden layer optimal satu layer.

4. Simpulan

Hasil pengujian menunjukkan akurasi pengujian terbaik, yaitu 90,5% dengan AUC .975 dan jumlah hidden layer optimal yaitu satu layer. Jadi, Multilayer Perceptron (MLPNN) dapat digunakan untuk mengklasifikasi tiga belas faktor yang mempengaruhi asfiksia sehingga didapatkan tingkatan pada kejadian asfiksia yaitu asfiksia sedang dan asfiksia berat.

Daftar Pustaka

- [1] Aminullah A. Ilmu Kebidanan Jakarta: YBPSB; 2005.
- [2] Handerson C. Buku Ajar Konsep Kebidanan Jakarta: EGC; 2006.
- [3] Wiknojosastro. Ilmu Kebidanan Jakarta: Yayasan Bina Pustaka Prawirohardjo; 1999.
- [4] Low JA. Intrapartum fetal asphyxia: definition, diagnosis, and classification. American Journal of Obstetrics and Gynecology. 1997.
- [5] A. Protopapasa and PDE. Perceptual differences in infant cries revealed by modifications of acoustic features. Acoustical Society of America. 1997; vol. 102.
- [6] O. F. Reyes-Galaviz CAR.G. "A System for the Processing of Infant Cry to Recognize Pathologies in Recently Born Babies with Neural Networks. SPECOM. 2004.
- [7] Zabidi A, Khuan LY. Classification of Infant Cries with Asphyxia Using Multilayer Perceptron Neural Network. IEEE. 2010.
- [8] A A. Meta-Learning Evolutionary Artificial Neural Networks, Neurocomputing. 2004;(56:1-38).
- [9] Dash S, Dash A. A Correlation based Multilayer Perceptron algorithm for Cancer Classification with Gene-Expression Dataset. IEEE. 2014.
- [10] Prawiroharjo S. Ilmu Kebidanan Jakarta: Yayasan Bina Pustaka; 2006.
- [11] Alpaydin E. Introduction to Machine Learning: Second Edition London: The MIT Press; 2010.
- [12] Michal RZ, Michael B, and Ido K. Learnability of periodic activation functions: General results: http://www.ics.uci.edu/~michal/p3606_1.pdf; 1998.
- [13] L. K W. Receiver operating characteristic (ROC) analysis, Evaluating discriminance effects among decision support systems. .