



1. Penyerahan Naskah (Submitted Paper)



2. Proses Review



Kotak Masuk (2.508) - fitrasept: x JTIK [JTIK] Keputusan Editorial arti: x (72) WhatsApp x Jual TAS ZARA SELEMPANG FRE: x +

Getting Started

https://mail.google.com/mail/u/0/#search/jtiik%40ub.ac.id/FMfcgwxKkHjZCJKGgsqQHPMk/VKdpDvd

Getting Started

Mail 99+ Chat Meet

Compose

Inbox 2,425

Starred

Snoozed

Sent

Drafts 11

More

Labels +

Search: jtiik@ub.ac.id

Active

6 of 10

1. Hasil dari program tersebut akan ... (jika hasil tersebut benar, batas maksimum adalah 25%). Detail file hasil plagiasi dapat diunduh melalui menu 'Ringkasan - Singkatan File Tambahan' dengan nama file '.....'. Silahkan jika ingin diparaphrase kembali kata-kata yang terblok dengan warna untuk meminimalkan plagiasi dengan dokumen online.

2. Untuk melihat apa yang perlu direvisi dari reviewer dan editor:

a. Login di jtiik.ub.ac.id sebagai Penulis

b. Klik menu "Beranda Pengguna", lalu klik "1 Aktif"

c. Pada Status, klik "Dalam Review: Revisi Dibutuhkan" (Untuk melihat revisi dari reviewer atau editor, pada "Keputusan Editor", pada "Beritahu Editor", bisa klik simbol 'comment')

3. Perbaiki naskah sesuai dengan masukan dari reviewer atau editor, kemudian tandai hasil revisi pada naskah revisi yang dikirimkan berupa pemberian highlight berwarna kuning pada kalimat yang diperbaiki atau kalimat yang ditambahkan sebagai bentuk pemenuhan revisi dari para Reviewer.

4. Naskah yang telah direvisi, bisa dikirimkan kembali melalui sistem OJS di website jtiik.ub.ac.id dan batas maksimal pengiriman revisi paling lambat (2 minggu). Petunjuk untuk mengirimkan naskah yang sudah direvisi:

a. Ikuti langkah pada nomor 2a, 2b, dan 2c.

b. Pada "Keputusan Editor", klik "Choose File" dan pilih file naskah yang sudah direvisi, lalu klik "Unggah".

5. Berikan penjelasan juga jawaban atau komentar terhadap tinjauan yang telah dilakukan oleh para Reviewer yang ditugaskan dalam bentuk file.

Kotak Masuk (2.508) - fitrasept: x JTIK [JTIK] Keputusan Editorial arti: x (73) WhatsApp x +

Getting Started

https://mail.google.com/mail/u/0/#search/jtiik%40ub.ac.id/FMfcgwxKkHjZCJKGgsqQHPMk/VKdpDvd

Getting Started

Mail 99+ Chat Meet

Compose

Inbox 2,425

Starred

Snoozed

Sent

Drafts 11

More

Labels +

Search: jtiik@ub.ac.id

Active

6 of 10

1. Kontribusi paper terhadap subyek penelitian:
Kontribusi paper ini sudah cukup dapat diapresiasi. Prediksi berat lahir bayi belum ada yang menggunakan autoencoder.


2. Originalitas paper:
Paper ini memiliki originalitas yang cukup. Namun perlu menurunkan similarity index yang 23% menjadi di bawah 20%

3. Kelayakan abstrak:
Pada abstrak hasil eksperimen masih belum dijelaskan lebih baik dari metode apa. Kalimat terakhir abstrak kurang bagus, dan kata sehingga seharusnya tidak menjadi awal kalimat karena kata sambung.


4. Kejelasan sistematika dan penyajian paper:
Secara umum sistematika dan penyajiannya cukup. Beberapa hal yang mengganggu adalah gambar 4 dan gambar 5, apakah gambar yang sama atau bukan, caption gambar tersebut menumpuk pada satu gambar, Tabel 11 terpotong sehingga terlihat kurang rapih.

5. Kelengkapan dan kemutakhiran pustaka:
Pustaka cukup representatif dan mutakhir, hanya penulisannya saja yang terdapat beberapa kesalahan atau tidak lengkap. Tolong diperiksa lagi yang tidak lengkap judul, nama jurnalnya tidak ada dsb.

6. Tata bahasa penulisan paper:
Ada beberapa kesalahan penulisan pada beberapa bagian, bisa



3. LOA



AUTOENCODER UNTUK SISTEM PREDIKSI BERAT LAHIR BAYI

Fitra Septia Nugraha^{*1}, Hilman Ferdinandus Pardede²

^{1,2}Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri, DKI Jakarta

²Badan Riset dan Inovasi Nasional

Email: ¹fitra.fig@nusamandiri.ac.id, ²hilman@nusamandiri.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 21 September 2020, diterima untuk diterbitkan: 16 Februari 2022)

Abstrak

Salah satu ukuran terpenting saat awal persalinan adalah keakuratan prediksi berat lahir. Dengan menggunakan metode prediksi yang tepat, perkiraan ekstrim berat lahir bayi dapat dideteksi lebih atau kurang sehingga beberapa tindakan pencegahan dapat dilakukan sebelum persalinan. Di sisi lain, untuk meningkatkan akurasi suatu proses pembelajaran, dibutuhkan suatu prediksi yang akurat untuk masalah yang dihadapi atau dengan menggunakan gabungan beberapa metode. Penelitian bertujuan untuk prediksi berat lahir bayi menggunakan metode *Deep Learning autoencoder* untuk memprediksi berat lahir bayi. Salah satu tantangan dalam pengembangan sistem prediksi berat lahir bayi adalah datanya yang berdimensi tinggi. Teknik konvensional untuk *feature reduction* seperti *principal component analysis* (PCA), mengasumsikan *orthogonality* atau independensi antar komponen prinsipal nya. Dengan *autoencoder*, asumsi tersebut tidak ada. Sehingga *autoencoder* dapat memodelkan korelasi antar fitur. Dengan melakukan variasi parameter pada *autoencoder*, performa terbaik diperoleh adalah MSE 0.002, MAE 0.029, R^2 0.991 dengan *autoencoder* dengan 4 lapisan *hidden layer encoder* dan *decoder*. Ini lebih baik dibandingkan PCA.

Kata kunci: Algoritma *Deep Learning*, *Autoencoder*, Normalisasi, *Feature reduction*, Berat lahir bayi

AUTOENCODER FOR INFANT BIRTH WEIGHT PREDICTION SYSTEM

Abstract

One of the most important measurements at the onset of labor is the accuracy of the prediction of birth weight. By using precise prediction methods extreme estimates of baby birth weight can be detected more or less so that some precautions can be taken before delivery. On the other hand, to improve the accuracy of a learning process, an accurate prediction is needed for the problem at hand or by using a combination of several methods. This study aims to predict baby birth weight using the *Deep Learning autoencoder* method to predict baby birth weight. One of the challenges in developing a predictive system for infant birth weight is the high dimensional data. Conventional techniques for feature reduction, such as *principal component analysis* (PCA), assume *orthogonality* or independence between the principal components. With an *autoencoder*, that assumption doesn't exist. So that the *autoencoder* can model the correlation between features. By varying the parameters of the *autoencoder*, the best performance is MSE 0.002, MAE 0.029, R^2 0.991 with an *autoencoder* with 4 hidden layer encoder and decoder layers. This is better than PCA.

Keywords: *Deep Learning Algorithm*, *Autoencoder*, Normalization, *Feature reduction*, Infant birth weight

1. PENDAHULUAN

Salah satu indikator utama kematian neonatal adalah Berat Bayi Lahir Rendah (BBLR). WHO mengungkapkan, pada tahun 2015, beberapa penyebab kematian neonatal diantaranya yaitu infeksi 33%, trauma 28%, BBLR 24%, kelainan bawaan 10% dan faktor lain 5%. BBLR memiliki Resiko kematian 4 kali lebih besar dibandingkan dengan berat bayi lahir lebih dari 2500 gram Yulifah dan Yuswanto dalam (Yasin and Ispriyansti, 2017). BBLR memiliki

resiko jangka panjang bagi tumbuh kembang anak dan beresiko memiliki penyakit jantung dan diabetes di masa yang akan datang Trihardiani dalam (Kusumawati, Septiyaningsih and Kania, 2016). Gangguan pada pernapasan, susunan saraf pusat, kardiovaskular, hematologi, gastro intestinal, ginjal dan termoregulasi adalah masalah yang sering terjadi pada BBLR (Yasin and Ispriyansti, 2017) (Kuhle *et al.*, 2018). BBLR dapat disebabkan oleh persalinan premature (persalinan dengan gestasi

< 37 Minggu) ataupun karena *Intrauterin Growth Restriction* (IUG) (Anggraini and Septira, 2016).

Oleh karena itu, Salah satu pengukuran yang terpenting pada awal persalinan adalah ketepatan prediksi berat bayi lahir. Dengan menggunakan metode prediksi yang tepat perkiraan berat lahir bayi yang ekstrim lebih atau kurang dapat dideteksi sehingga pencegahan dapat dilakukan sebelum persalinan (Nindrea, 2017).

Penelitian prediksi berat lahir bayi ini sebelumnya sudah pernah dilakukan oleh para peneliti, H. Yasin and D. Ispriyanti tahun 2017 meneliti klasifikasi berat bayi lahir menggunakan *Weighted Probabilistic Neural Network* (WPNN) dari hasil penelitian diperoleh model WPNN memiliki akurasi yang sangat tinggi yaitu sebesar 98,75% atribut yang digunakan adalah umur ibu, usia kehamilan, tinggi ibu, berat ibu, tensi darah ibu, *hemoglobin* ibu, paritas dan berat bayi lahir sebagai label (Yasin and Ispriyanti, 2017). Penelitian lain A. Puspita and M. Wahyudi pada tahun 2015 meneliti klasifikasi kelahiran bayi premature menggunakan algoritma C4.5 dari hasil prediksi memberikan nilai akurasi sebesar 93.60% atribut yang digunakan dalam penelitian ini dengan melihat umur ibu, sistol, diastol, riwayat darah tinggi, riwayat keguguran, riwayat premature, asfiksia atau trauma, pengguna rokok, konsumsi ganja, keputihan dan hasil (Puspita and Wahyudi, 2015). Penelitian lain Jefa pada tahun 2019 meneliti prediksi klasifikasi bayi prematur menggunakan metode C4.5 berbasis *Particle Swarm Optimization* (PSO) terdapat beberapa masalah kesehatan yang dapat mengakibatkan terjadinya persalinan premature yaitu kesehatan ibu yang kurang, pengguna rokok, catatan kehamilan sebelumnya, keadaan janin dan keadaan psikologis hasil penelitian algoritma C4.5 dengan menggunakan PSO diperoleh akurasi sebesar 97,91% (Jefa, 2019). Penelitian lain S. Kuhle *et al.* pada tahun 2018 meneliti perbandingan algoritma *Logistic Regression* dengan algoritma klasifikasi mesin learning lainnya untuk memprediksi kelainan pertumbuhan janin pada wanita *primipara* dan *multipara* dengan fitur-fitur yang digunakan dalam penelitian ini dilihat dari beberapa faktor yaitu faktor *socio demographics* yaitu usia ibu, status pernikahan, pendapatan dan tempat kemudian faktor resiko kehamilan yaitu merokok, BMI sebelum kehamilan, hipertensi, diabetes, penggunaan zat dan gangguan kejiwaan hasil penelitian menunjukan bahwa metode pembelajaran mesin yang digunakan dalam penelitian ini tidak memberikan kelebihan dibandingkan dengan *Logistic Regression* dengan akurasi 60 – 75 % (Kuhle *et al.*, 2018). Selanjutnya penelitian Yueh-Chin Cheng, dkk pada tahun 2012 meneliti klasifikasi ukuran janin yang efisien dikombinasikan dengan jaringan saraf tiruan untuk estimasi berat janin, memanfaatkan algoritma K-means untuk mengklasifikasi ukuran janin yang selanjutnya digunakan untuk pelatihan JST untuk meningkatkan

akurasi prediksi berat janin, fitur-fitur yang dipakai dalam penelitian ini diambil dari data pemeriksaan USG prenatal yaitu lingkaran perut (AC), *diameter biparietal* (BPD), berat lahir (BW), panjang femur (FL), presentasi janin (FP), usia kehamilan (GA), lingkaran kepala (HC), *diameter oksipitofrontal* (OFD) dan jenis kelamin hasil penelitian diperoleh MAPE 5,26 4,14 % dan MAE 157,91 119,90 g (Cheng *et al.*, 2012).

Salah satu tantangan dalam penerapan sistem prediksi berat lahir adalah besarnya dimensi data. Teknik konvensional untuk *feature reduction* seperti *principal component analysis* (PCA) (Kristian *et al.*, 2018). PCA adalah salah satu metode reduksi data yang cukup unggul karena penggunaannya yang sederhana dan mudah untuk diimplementasikan dan mampu mengelemenasi korelasi antar variabel inputan. Akan tetapi terdapat kekurangan dalam PCA yang mana PCA hanya mereduksi data secara linier sedangkan kita ketahui sering terjadi hubungan data secara nonlinear.

ANN atau *Artificial Neural Network* merupakan suatu metode machine learning yang mempunyai struktur tersebar paralel yang sangat besar dengan kemampuan belajar yang sangat baik, ANN dapat menghasilkan keluaran yang tepat dari masukan yang belum pernah dilatihkan sebelumnya. Sehingga dengan kemampuan ini ANN mampu menyelesaikan masalah-masalah yang sangat kompleks, mulai dari klasifikasi, optimasi, kompresi, peramalan (*forecasting*), sistem kontrol, sistem pendeteksian kecurangan (*intrusion detection system*) dan sebagainya. ANN sangat sesuai untuk permasalahan yang bernilai kontinyu seperti pengenalan tulisan tangan, pengenalan wajah, peramalan kurs tengah mata uang dan sebagainya (Informasi *et al.*, 2015). ANN juga dapat melakukan pembelajaran data tidak hanya untuk data linear saja tetapi dapat digunakan untuk data non-linear (Informasi *et al.*, 2015).

ANN memiliki kemampuan untuk diterapkan sebagai metode *feature reduction*. Karena ANN menggunakan fungsi nonlinear. ANN dapat dilihat sebagai metode nonlinear PCA yang tidak menggunakan asumsi independensi antar data. Salah satu arsitektur ANN yang sering digunakan untuk itu adalah *Autoencoder*. *Autoencoder* adalah model neural network yang mempelajari data input dan berusaha untuk melakukan rekonstruksi terhadap data input tersebut. Dengan kemampuan menemukan *hidden structure* dari data, *Autoencoder* dapat melakukan kompresi dengan baik dan dapat juga mempelajari fitur non linear (Putra, 2019). Dalam proses pelatihannya *Autoencoder* menggunakan teknik *supervised learning*, akan tetapi tidak membutuhkan kelas dari data sebagai target. *Autoencoder* merupakan sebuah metode yang memiliki dua bagian utama yaitu *Encoder* dan *Decoder*, *Autoencoder* memiliki jumlah masukan dan keluaran yang sama dan selalu berbentuk simetris atau jam pasir. Selain itu juga memiliki layer code,

dan jumlah neuron pada layer code merupakan jumlah dimensi yang mengurangi dimensi yang terdapat pada data (Fauzi *et al.*, 2019) (Kristian *et al.*, 2018). Kelebihan dari metode ini adalah dapat melakukan *hierarchical feature learning* dari data yang digunakan, sehingga dapat menciptakan representasi bertingkat dimana representasi tersebut semakin abstrak dari tingkatan sebelumnya sehingga diharapkan menghasilkan representasi yang baik (Prodi *et al.*, 2017). Autoencoder juga dapat digunakan untuk mengabaikan sinyal (noise) atau derau dari data masukan yang disebut dengan *Denoising Autoencoder* (Kristian *et al.*, 2018). *Denoising Autoencoder* memiliki ciri yang sama dengan *Autoencoder* hanya saja didalam *Denoising Autoencoder* data yang diproses adalah data yang telah diberi noise sehingga pelatihan atau proses training akan menghasilkan data yang abstrak dibandingkan dengan *Autoencoder* biasa (Prodi *et al.*, 2017).

Dalam pengolahan dataset sering kita jumpai data yang memiliki ukuran yang besar baik dalam hal jumlah fitur. Jumlah fitur yang semakin besar dapat mempengaruhi pada beberapa hal seperti waktu komputasi lama dan terjadinya *curse of dimensionality* (Upaya and Komponen, 2014), hal ini dapat mengakibatkan banyak analisis data yang lebih berat seiring meningkatnya jumlah dimensi dari data. Semakin meningkatnya jumlah dimensi data maka semakin meningkat pula sebaran tempat yang dibutuhkan. Untuk klasifikasi maupun prediksi, hal ini menunjukkan bahwa tidak ada objek data yang cukup handal yang bisa digunakan untuk membuat model handal yang mampu melabeli kelas di semua obyek yang ada. Hasilnya, banyak algoritma klasifikasi dan prediksi pada data dengan dimensi tinggi menghasilkan akurasi yang rendah.


Faktor-faktor yang dapat mempengaruhi terhadap berat badan bayi lahir adalah jenis kelamin, ras, plasenta, usia ibu, aktivitas atau kegiatan ibu selama kehamilan, merokok, paritas, jarak kelahiran dari kelahiran sebelumnya, tinggi badan dan berat badan ibu sebelum kehamilan, status sosial ekonomi, gizi. Dengan memperhatikan faktor-faktor tersebut dapat mendukung dalam pemantauan kesehatan ibu hamil dan bayi dengan melihat pertumbuhan berat badan ibu setiap bulannya. Setiati dkk dalam (Finandakasih, Rosmah and Tiro, 2018).

Penelitian yang akan dilakukan ini adalah penerapan algoritma *Deep learning* dengan metode *Autoencoder* dalam memprediksi berat badan bayi lahir, dan sebagai pembandingan digunakan metode PCA. Hasil penelitian menunjukkan bahwa *Autoencoder* dapat menghasilkan akurasi terbaik dalam sistem prediksi berat bayi lahir.

Makalah ini disusun sebagai berikut.

2. METODE PENELITIAN

2.1 Tahapan Penelitian



Gambar 1. Metode Penelitian

2.2 Dataset

Data pada penelitian ini menggunakan data sekunder yang didapat dari web online *Kaggle*. Data yang digunakan adalah data dari *Doyonghoon* yaitu baby-data, dengan jumlah data 1236 record dan 23 atribut. Spesifikasi dataset yang digunakan dalam penelitian ini sebagai berikut.

Tabel 1. Atribut Dataset Baby-data

Atribut	Keterangan
<i>Id</i>	Id responden
<i>Plurality</i>	Banyaknya janin
<i>Outcome</i>	Kelahiran hidup yang bertahan setidaknya 28 hari
<i>Date</i>	Tanggal lahir
<i>Gestation</i>	Jumlah hari kehamilan
<i>Sex</i>	Jenis kelamin
<i>Parity</i>	Anak ke-
<i>Race</i>	Ras Ibu
<i>Age</i>	Usia Ibu
<i>Ed</i>	Pendidikan Ibu
<i>Ht</i>	Tinggi badan Ibu
<i>Wt.1</i>	Berat badan Ibu sebelum kehamilan
<i>Drace</i>	Ras Ayah
<i>Dage</i>	Usia Ayah
<i>Ded</i>	Pendidikan Ayah
<i>Dht</i>	Tinggi badan Ayah
<i>Dwt</i>	Berat Badan Ayah
<i>Marital</i>	Status Pernikahan
<i>Inc</i>	Total pendapatan dalam peningkatan 2500
<i>Smoke</i>	Ibu meroko
<i>Time</i>	Berapa Lama berhenti meroko
<i>Number</i>	Jumlah kuantitas meroko dalam sehari

2.3 Data Preprocessing

Pada penelitian ini dilakukan beberapa *preprocessing* data, yaitu dengan menggunakan *Feature Selection*, *Replace Missing*, Normalisasi dan *preprocessing* data transformation yaitu mengubah suatu data menjadi data yang lebih berkualitas menggunakan dimensionality reduction PCA dan Autoencoder. Tahap *preprocessing* dilakukan untuk

mempermudah dalam melakukan eksperimen terhadap model yang tepat. Selain itu tahap *preprocessing* dilakukan untuk mendapatkan *Mean Square Error* (MSE) yang lebih kecil. Berikut ini beberapa metode *preprocessing* yang digunakan dalam penelitian ini:

a. Feature Selection

Feature Selection merupakan salah satu indikator penting yang dapat berpengaruh terhadap hasil akurasi karena jika data terdapat sejumlah fitur, maka dimensi data akan menjadi semakin besar yang dapat berakibat rendahnya nilai akurasi (Nugroho and Wibowo, 2017). *Feature Selection* dalam penelitian ini menggunakan metode *matrix correlation*. *Matrix correlation* berguna untuk menginvestigasi seluruh hubungan antar variabel numerik dalam dataset.

b. Replace Missing Value

Metode *Missing value* yang digunakan menggunakan metode mean yaitu dengan mereplace nilai yang hilang dengan nilai rata-ratanya..

c. Normalisasi

Metode normalisasi adalah merubah data kedalam range antara 0 dan 1. Metode – metode yang digunakan adalah sebagai berikut:

1. StandarScaler

StandarScaler adalah teknik untuk mentransformasikan tiap fitur memiliki nilai rata-rata 0 dan variansi 1.

2. MinMaxScaler


MinMaxScaler berfungsi untuk mengubah data berada dalam rentang 0 sampai 1 (Chamidah, Wiharto and Salamah, 2012).

d. Data Transformation

Setelah data bersih dari *missing value*, data terduplikasi dan data yang tidak konsisten dilakukan *preprocessing* phase 2 dengan penambahan metode *feature reduction* dan *feature extraction*. *Feature reduction* disini dengan penambahan metode *Principal Component Analysis* (PCA) untuk mereduksi variabel sehingga dari variabel yang ada pada dataset akan diperoleh variabel baru yang mewakili variabel asal. Sedangkan *feature extraction* disini dengan menambahkan metode *Autoencoder* untuk mengekstraksi fitur penting dari data lalu merekonstruksinya kembali.

2.4 Desain Eksperimen

Tahap eksperimen terdiri atas dua bagian yaitu, pertama membandingkan hasil prediksi berat bayi lahir antara model autoencoder dan PCA berdasarkan teknik scaling data *MinMaxScaler* dan *StandarScaler*. Kedua, variasi parameter untuk mencari hasil prediksi yang lebih baik.



Gambar 2. Arsitektur Autoencoder

Pada Gambar 2. menunjukan arsitektur yang di pakai dalam penelitian ini yaitu arsitektur *Deep learning Autoencoder*. Secara teori, pada metode ANN tidak ada aturan secara baku untuk menentukan arsitektur ANN yang optimal untuk diterapkan ke dalam sistem Kardan et al. dalam (Badieah, Gernowo and Surarso, 2016). Sehingga pencarian arsitektur dan parameter pelatihan ANN harus dilakukan secara *trial* dan *error*. Ringkasan variasi arsitektur *Deep learning Autoencoder* jaringan pada eksperimen ini ditunjukkan pada Tabel 2 dan sebagai pembanding PCA ditunjukkan pada Tabel 3.

Tabel 2. Arsitektur Autoencoder Yang Diujicobakan

Model	Input	Encoder		Output Neuron	Decoder		Output Neuron
		Hidden layer	Hidden Neuron		Hidden layer	Hidden Neuron	
1	18	1	32	18	1	16	1
2	18	2	32-16	18	2	16-8	1
3	18	3	64-32-64	18	3	32-16-32	1
4	18	4	128-64-32-128	18	4	64-32-16-64	1

Tabel 3. Arsitektur PCA Yang Diujicobakan

Model	Feature Reduction	Jumlah		
		Input neuron	Hidden Layer	Hidden Neuron
1	PCA	17	1	16
2		17	2	16-32
3		17	3	16-32-8
4		17	4	16-32-8-32

Untuk melakukan ujicoba pelatihan deep learning ANN langkah selanjutnya adalah menentukan parameter pelatihan. Pada penelitian ini, konfigurasi parameter yang di ujikan ditampilkan pada Tabel 4.

Tabel 4. Konfigurasi Parameter

Parameter	Nilai Parameter Yang Diujicobakan
Optimizer	Adam lr 0.001
Momentum	0.9
Epoch	45
Batch Size	12
Aktivasi Hidden Layer	Relu
Aktivasi Hidden Layer	Custom_gelu
Encoder	
Aktivasi Hidden Layer	Relu
Decoder	
Aktivasi Output	Linear

Setelah diperoleh model dan metode yang menghasilkan prediksi berat lahir bayi optimal, untuk memastikan hasil dari pengujian model terpilih adalah yang terbaik diperlukan suatu perbandingan parameter yang lainnya. Dalam perbandingan parameter ini akan dibandingkan adalah nilai *learning rate*.

Tabel 5. Perbandingan Paramater

	Nilai Parameter			
Learning rate	0.001	0.002	0.003	0.004

3. DASAR TEORI

3.1 Berat Bayi Lahir

Berat bayi lahir adalah berat badan bayi yang di timbang dalam waktu 1 jam pertama setelah lahir (Wahyuni *et al.*, 2020). Terdapat 3 kelompok berat bayi lahir berdasarkan umur kehamilan yaitu pertama BKB atau bayi kurang bulan, yaitu bayi yang dilahirkan dengan usia kehamilan kurang dari 37 minggu (259 hari). Kedua BCB atau bayi cukup bulan, yaitu bayi yang dilahirkan dengan usia kehamilan antara 37 sampai dengan 42 minggu (259 - 293 hari), dan ketiga BLB atau bayi lebih bulan, yaitu bayi yang dilahirkan dengan usia kehamilan lebih dari 42 minggu (294 hari) (WIBOWO, 2017).


Atribut yang digunakan dalam penelitian ini adalah jumlah janin, outcome, tanggal lahir, hari kehamilan, jenis kelamin bayi, paritas, ras ibu, usia ibu, pendidikan ibu, tinggi ibu, berat ibu pra kehamilan, ras ayah, usia ayah, pendidikan ayah, tinggi ayah, berat ayah, status perkawinan, total pendapatan, ibu merokok, frekuensi merokok, quantity merokok sehari dan berat lahir bayi sebagai label. Harapam dari hasil penelitian ini akan bermanfaat untuk masyarakat Indonesia khususnya kepada ibu hamil yang sedang mempersiapkan untuk proses persalinan yang baik dan tidak merugikan luaran bayi.

3.2 Artificial Neural Network

Artificial Neural Network (ANN) merupakan jaringan sebuah sistem pemrosesan data yang dimodelkan berdasarkan sistem saraf otak manusia maupun hewan. ANN lahir Pada tahun 1943 berawal dari gagasan psikolog yaitu Warren McCulloch dan Walter Pitts yang menjelaskan bagaimana cara kerja jaringan saraf dengan perangkat jaringan elektronik. ANN adalah suatu sistem yang memiliki banyak elemen pemroses yang mempunyai struktur tersebar paralel yang sangat besar yang saling terhubung (Azhar, Riksakomara and Terkait, 2017).

Artificial Neural Network, memiliki banyak layer sehingga sulit untuk dibaca dan dimengerti oleh manusia kecuali jika modelnya *single perceptron*, dan sifat *non-linear* yang merujuk pada penggunaan fungsi aktivasinya. ANN sering disebut dengan agnostik karena kita percaya untuk hasilnya benar akan tetapi sulit untuk membuktikan bahwa kenapa

pengaturan dari parameter yang dihasilkan training bisa benar. Konsep matematis ANN itu sendiri cukup solid, tetapi *interpretability* model rendah menyebabkan kita tidak dapat menganalisa proses inferensi yang terjadi pada model ANN. Secara matematis, ANN dapat diibaratkan graf yang terdiri dari vertex sebagai neuron/node kemudian edge sebagai sinapsis. Karena strukturnya sama seperti graf maka operasi pada ANN mudah dijelaskan dalam notasi linear aljabar. Sebagai gambaran ANN berbentuk seperti gambar berikut (Putra, 2019).



Gambar 3. Struktur Neural Network

3.3 Performa Peramalan

a. Mean Absolute Error (MAE)

MAE digunakan sebagai salah satu metode untuk mengukur tingkat keakuratan dalam sebuah model peramalan. Nilai MAE menunjukkan rata-rata error secara absolut antara hasil prediksi dengan nilai sebenarnya (Informatika and Ronggolawe, 2019). Berikut adalah rumus *Mean Absolute Error* (MAE).

$$MAE = \frac{1}{n} \sum_{i=1, n} |y - y'| \quad (20)$$

Keterangan:

MAE : *Mean Absolute Error* (MAE)

N : Jumlah Data

y' : Nilai sebenarnya

y : Nilai Hasil Peramalan

b. Mean Absolute Percentage Error (MAPE)

MAPE yaitu menjumlahkan setiap kesalahan absolut pada setiap periode setelah mengurangkan nilai peramalan dengan nilai aktual pada setiap periode tersebut dengan rumus berikut (Azhar, Riksakomara and Terkait, 2017):

$$MAPE = \left(\frac{100}{n} \right) \sum \left| \frac{At - Ft}{At} \right| \quad (21)$$

Keterangan :

At : Nilai aktual pada periode ke-t

Ft : Nilai Peramalan pada periode ke-t

n : Jumlah periode peramalan yang terlibat
Skala hasil error peramalan

Tabel 6. Skala Performa Peramalan

MAPE	Hasil Peramalan
< 10%	Sangat Baik
10 – 20%	Baik
20 – 50%	Layak/Cukup
>50%	Buruk


c. R^2 Score

Uji koefisien determinasi (R^2) digunakan untuk memprediksi atau melihat seberapa besar kontribusi pengaruh yang diberikan variabel independen (X) secara simultan terhadap variabel dependen (Y) dimana nilai R^2 berkisar antara 0 - 1 ($0 \leq R^2 \leq 1$). R^2 menunjukkan proporsi dari total variability yang dapat dijelaskan oleh model yang diperoleh. Jika model yang diperoleh nilai R^2 nya semakin kecil maka ini berarti pengaruh variabel independen terhadap variabel dependen semakin lemah. Sebaliknya apabila nilai R^2 semakin mendekati angka 1, maka pengaruh tersebut akan semakin kuat. Pada umumnya nilai R^2 lebih dari 0.9 mengindikasikan model yang bagus (Rachman, 2014)(Thaharah, 2016).

4. HASIL PENELITIAN


4.1. Eksperimen Dan Pengujian Model

Berikut ini merupakan hasil pemodelan semua percobaan yang dilakukan pada arsitektur *Denoising Autoencoder* dengan mengambil best model dan juga PCA.




Gambar 4. Perbandingan Akurasi Validasi untuk Beberapa Lapisan Tersembunyi Normalisasi MinMaxScaler

Pada eksperimen dengan variasi parameter jumlah *hidden layer* dan normalisasi *MinMaxScaler*, terlihat pada Gambar 4 bahwa dengan *Autoencoder*, jumlah *hidden layer* 4 sudah mendapatkan hasil akurasi terbaik, sementara dengan PCA hasil terbaik untuk jumlah *hidden layer* 4 juga. Meskipun demikian, hasil akurasi terbaik dengan *Autoencoder*, yaitu dengan MSE 0.0003, MAE 0.014 dan R^2 0.98 masih jauh lebih tinggi dari akurasi terbaik dengan PCA, yaitu MSE 0.191, MAE 0.346 dan R^2 0.149. Berdasarkan Gambar 4 Dari hasil pengujian ke 4 model *Autoencoder* dan PCA dengan metode normalisasi *MinMaxScaler* menunjukkan bahwa variasi *hidden layer* sangat mempengaruhi performa hasil akurasi, dengan variasi *hidden layer* yang tepat akan memberikan hasil akurasi yang baik. Dari hasil evaluasi menunjukkan bahwa dengan menambah jumlah *hidden layer*, dapat meningkatkan performa hasil ANN.



Gambar 5. Perbandingan Akurasi validasi Untuk Beberapa Lapisan Tersembunyi Normalisasi StandarScaler

Pada eksperimen dengan variasi parameter jumlah *hidden layer* dan normalisasi *StandarScaler*, terlihat pada Gambar 7. bahwa dengan *Autoencoder*, jumlah *hidden layer* 4 sudah mendapatkan hasil akurasi terbaik, sementara dengan PCA hasil terbaik untuk jumlah *hidden layer* 2. Meskipun demikian, hasil akurasi terbaik dengan *Autoencoder*, yaitu dengan MSE 0.002, MAE 0.03 dan R^2 0.992 masih jauh lebih tinggi dari akurasi terbaik dengan PCA, yaitu MSE 0.188, MAE 0.353 dan R^2 0.162. Berdasarkan Gambar 5. Dari hasil pengujian ke 4 model *Autoencoder* dengan metode normalisasi *StandarScaler* menunjukkan bahwa variasi *hidden layer* sangat mempengaruhi performa hasil akurasi, dengan variasi *hidden layer* yang tepat akan memberikan hasil akurasi yang baik. Dari hasil evaluasi menunjukkan bahwa dengan menambah jumlah *hidden layer*, dapat meningkatkan performa hasil ANN akan tetapi berbeda halnya pada model PCA dengan normalisasi *StandarScaler* penambahan jumlah *hidden layer* tidak meningkatkan performa hasil ANN.



Gambar 6. Perbandingan Akurasi Validasi Autoencoder Untuk Metode Normalisasi

Perbandingan akurasi validasi *Autoencoder* dengan variasi normalisasi, yaitu pada Gambar 6. menunjukkan bahwa nilai terbaik adalah MSE 0.002, MAE 0.03, MAPE 0.959 dan R^2 0.992, yaitu pada penggunaan metode normalisasi *StandarScaler*. Sementara untuk penggunaan normalisasi *MinMaxScaler*, nilai akurasi terbaik adalah MSE 0.003, MAE 0.014, MAPE 3.042 dan R^2 0.98, hanya berbeda sedikit dari akurasi untuk penggunaan *Autoencoder StandarScaler*.

feature Reduction	Hidden Layer	MinMaxScaler				StandarScaler			
		MSE	MAE	MAPE	R ²	MSE	MAE	MAPE	R ²
AE	1	0.013	0.091	21.632	0.317	0.095	0.240	7.285	0.576
	2	0.012	0.088	20.898	0.384	0.103	0.250	7.466	0.543
	3	0.002	0.041	9.269	0.854	0.010	0.073	2.246	0.955
PCA	4	0.003	0.014	3.042	0.980	0.002	0.030	0.959	0.992
	1	0.193	0.349	10.696	0.141	0.192	0.356	10.759	0.145
	2	0.196	0.356	10.960	0.124	0.188	0.353	10.844	0.162
	3	0.195	0.348	10.588	0.133	0.191	0.346	10.691	0.148
	4	0.191	0.346	10.562	0.149	0.192	0.350	10.673	0.144

Tabel 7. Evaluasi Hasil

Pada penelitian ini, terbukti bahwa metode normalisasi yang tepat dapat cukup efektif dalam memperbaiki akurasi validasi. Hasil penelitian menunjukkan bahwa metode normalisasi *StandarScaler* lebih baik dalam memprediksi berat bayi lahir.

4.2. Evaluasi dan Validasi

Dalam evaluasi hasil penelitian, dilakukan perbandingan nilai MSE, MAE, MAPE dan R² berdasarkan jumlah *hidden layer* dan metode normalisasi yang digunakan. Setelah dilakukan pengujian pada setiap model yang diusulkan, langkah selanjutnya adalah melakukan perbandingan pada kinerja model regresi yang diujikan.

Dari hasil-hasil eksperimen perbandingan penggunaan *Autoencoder* dan PCA serta metode normalisasi yang digunakan, secara umum terlihat bahwa penggunaan *Deep Learning Autoencoder* selalu mendapatkan akurasi yang lebih baik dibanding pada penggunaan PCA baik menggunakan normalisasi MinMaxScaler maupun StandarScaler. Meskipun telah dilakukan pengkondisian dengan beberapa variasi parameter, hasil deep learning autoencoder lebih baik. Hal ini dikarenakan *Deep Learning Autoencoder* dapat mampu mengatasi data yang bersifat *nonlinear*.

Berdasarkan hasil eksperimen pada Tabel 7, terlihat bahwa semakin banyak lapisan *hidden layer* cenderung semakin akurat. Hal ini dilihat dari rerata semua eksperimen, bahwa rerata akurasi dari 4 lapisan *hidden layer* selalu lebih tinggi dari ke tiga lapisan lainnya. Sementara itu hasil akurasi terbaik yang diperoleh adalah dengan MSE 0.002, MAE 0.03, MAPE 0.959 dan R² 0.992, yaitu untuk penggunaan 4 lapisan *hidden layer* dengan variasi *hidden neuron encoder* berturut-turut 128, 64, 32, 128 dan *hidden neuron decoder* berturut-turut 64, 32, 16,

64 menggunakan teknik scaling data yaitu normalisasi *StandarScaler*.

4.3. Perbandingan Parameter

Untuk memastikan hasil dari parameter ANN yang terpilih adalah yang terbaik diperlukan suatu perbandingan parameter yang lainnya. Dalam perbandingan parameter ini akan dibandingkan adalah nilai *learning rate*. Perbandingan kinerja model berdasarkan *learning rate* disajikan dalam tabel berikut ini.


Tabel 8. Perbandingan Performa Variasi Learning Rate

Learning Rate	ANN Autoencoder			
	MSE	MAE	MAPE	R ²
0.001	0.002	0.030	0.959	0.992
0.002	0.002	0.031	1.000	0.991
0.003	0.002	0.029	0.898	0.991
0.004	0.002	0.037	1.156	0.989

Dilihat pada Tabel 8, penggunaan variasi *learning rate* yang digunakan dikatakan berpengaruh kecil terhadap hasil akhir peramalan, yaitu dilihat dari hasil test error yang cenderung stabil. Berdasarkan hasil implementasi dan hasil analisis pada penelitian ini, maka didapatkan model yang paling optimal adalah *Deep Learning Autoencoder* dengan *learning rate* 0.003.

Untuk mengetahui erat atau tidaknya hubungan, arah hubungan dan berarti tidaknya hubungan antar variabel input independen dengan variabel output atau dependen dapat dilihat dari nilai MAPE dan R². Hasil kesalahan MAPE pada model terpilih diperoleh MAPE sebesar 0.898 sehingga dapat dikatakan semua fitur mempengaruhi dengan sangat baik terhadap hasil akhir peramalan (MAPE < 10 % : Sangat Baik). Sedangkan berdasarkan nilai R² 0.991 dapat dikatakan semua fitur secara bersama-sama sangat mempengaruhi dengan baik terhadap

hasil akhir peramalan (R^2 score mendekati nilai 1). Berikut ini grafik hasil test error pada model optimal:



Gambar 7. Grafik Test Error Model Optimal

5. KESIMPULAN

Penelitian ini dibuat untuk mencari model terbaik dalam *Deep learning Autoencoder* yang menghasilkan akurasi terbaik dalam memprediksi berat bayi lahir. Hasil penelitian menunjukkan performa terbaik diperoleh adalah MSE 0.002, MAE 0.029, MAPE 0.898 dan R^2 0.0991 dengan *autoencoder* dengan 4 lapisan *hidden layer encoder* dan *decoder* serta normalisasi StandarScaler.

Berdasarkan nilai MAPE 0.898 dapat dikatakan bahwa semua fitur yang digunakan dalam penelitian ini mempengaruhi dengan sangat baik terhadap hasil akhir peramalan. Berdasarkan nilai R^2 score 0.991 dapat dikatakan bahwa 99,1% semua fitur secara bersama-sama sangat mempengaruhi dengan baik terhadap hasil akhir peramalan dan sebesar 0.9 % dapat dipengaruhi oleh faktor lain yang tidak digunakan dalam penelitian ini.

DAFTAR PUSTAKA

ANGGRAINI, D. I. & SEPTIRA, S. 2016. Nutrisi bagi Bayi Berat Badan Lahir Rendah (BBLR) untuk Mengoptimalkan Tumbuh Kembang Nutrition for Low Birth Weight Infant to Optimize Infant Growth and Development. Vol 5(September), pp. 151–155.

AZHAR, M., RIKSAKOMARA, E. & TERKAIT, A. P. 2017. Peramalan Jumlah Produksi Ikan dengan Menggunakan. Vol. 6(1), pp. 142–148.

BADIEAH, B., GERNOWO, R. & SURARSO, B. 2016. Metode Jaringan Syaraf Tiruan Untuk Prediksi Performa Mahasiswa Pada Pembelajaran Berbasis Problem Based Learning (PBL). *Jurnal Sistem Informasi Bisnis*, 6(1), p. 46. doi: 10.21456/vol6iss1pp46-58.

CHAMIDAH, N., WIHARTO & SALAMAH, U. 2012. Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagasi Gradient Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi. *ITSMART*, Vol 1. No(September 2018), pp. 28–33. doi: 10.20961/itsmart.v1i1.582.

CHENG, Y. C. dkk. 2012. Efficient fetal size

classification combined with artificial neural network for estimation of fetal weight. *Taiwanese Journal of Obstetrics and Gynecology*. Elsevier Taiwan LLC, 51(4), pp. 545–553. doi: 10.1016/j.tjog.2012.09.009.

FAUZI, M. R. dkk. 2019. Model Prediksi Cancer Menggunakan Autoencoder. Vol. 3(1).

FINANDAKASIH, F., ROSMAH, S. A. AND TIRO, M. A. 2018. Model Prediksi Berat Lahir Bayi Berdasarkan Faktor Pengaruhnya Di Puskesmas Kaluku Bodoa. *Prosiding Seminar nasional Variansi*, 2018, pp. 162–174. Available at: <http://ojs.unm.ac.id/index.php/varsistatistika>.

INFORMASI, J. T. ET AL. 2015. Optimasi Parameter Artificial Neural Network. Vol. 11, pp. 196–209.

INFORMATIKA, J. T. & RONGGOLAWA, U. P. 2019. Penerapan Metode Mean Absolute Error (MEA) Dalam Algoritma Regresi Linear Untuk Prediksi Produksi Padi. Vol. 1, pp. 78–83.

JEFI. 2019. Prediksi Bayi Lahir Secara Prematur Dengan Menggunakan Metode C. 45 Berbasis Particle Swarm Optimization Pada Klinik Umi', 8(2), pp. 1–7.

KRISTIAN, Y. dkk. 2018. Klasifikasi Nyeri pada Video Ekspresi Wajah Bayi Menggunakan DCNN Autoencoder dan LSTM', *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, 7(3), pp. 308–316. doi: 10.22146/jnteti.v7i3.440.

KUHLE, S. dkk. 2018. Comparison of logistic regression with machine learning methods for the prediction of fetal growth abnormalities: A retrospective cohort study. *BMC Pregnancy and Childbirth*, 18(1), pp. 1–9. doi: 10.1186/s12884-018-1971-2.

KUSUMAWATI, D. D., SEPTIYANINGSIH, R. & KANIA. 2016. Faktor-Faktor Ibu yang Mempengaruhi Kejadian Bayi Berat Lahir Rendah (BBLR). *Jurnal Kesehatan Al-Irsyad (JKA)*, 9(2), pp. 8–16.

NINDREA, R. D. 2017. Perbedaan Taksiran Berat Badan Janin Menurut Perhitungan Formula Berat Badan Lahir Bayi. *Jurnal Ipteks Terapan*, 11(1), p. 36. doi: 10.22216/jit.2017.v11i1.1389.

NUGROHO, M. F. & WIBOWO, S. 2017. Fitur Seleksi Forward Selection Untuk Menentukan Atribut Yang Berpengaruh Pada Klasifikasi Kelulusan Mahasiswa Fakultas Ilmu Komputer UNAKI Semarang Menggunakan Algoritma Naive Bayes. *Jurnal Informatika Upgris*, 3(1), pp. 63–70. doi: 10.26877/jiu.v3i1.1669.

PRODI, S. dkk. 2017. Denoising Sinyal Ekg Menggunakan Deep Neural Network Dengan

- Stacked Denoising Autoencoders Ecg Signal Denoising Using Deep Neural Network With Stacked Denoising Autoencoders. Vol. 4(3), Pp. 5024–5030.
- PUSPITA, A. & WAHYUDI, M. 2015. Algoritma C4.5 Berbasis Decision Tree untuk Prediksi Kelahiran Bayi Prematur. *Konferensi Nasional Ilmu Pengetahuan dan Teknologi (KNIT)*, 1(1), pp. 97–102. Available at: <http://konferensi.nusamandiri.ac.id/proceeding/index.php/KNIT/article/view/175>.
- PUTRA, J. W. G. 2019. Pengenalan Konsep Pembelajaran Mesin dan Deep Learning', pp. 1–235.
- RACHMAN, A. 2014. Model Peramalan Konsumsi Bahan Bakar Jenis Premium Di Indonesia Dengan', pp. 166–176.
- THAHARAH, N. 2016. Pengaruh Mekanisme Corporate Governance Dan Kinerja Keuangan Terhadap Nilai Perusahaan LQ 45', 5.
- UPAYA, D. AND KOMPONEN, P. 2014. Pendahuluan Set data yang diolah dalam sistem seperti', pp. 293–300.
- WAHYUNI, F. dkk .2020. Hubungan Lama Mengikuti Baby Spa Dengan Kenaikan Berat Badan Bayi Usia 0-6 Bulan Di Yayasan Ibu Kompleks Medan Permai Kota Medan Tahun 2018 Dosen S1 Kebidanan STIKES Senior Medan , Indonesia Alumni D4 Kebidanan , Institut Kesehatan Helvetia Background ; B', 2(2).
- WIBOWO, D. A. 2017. Pengaruh Terapi Massage Terhadap Peningkatanberat Badan Bayi Prematur Di Ruang Perinatologi Rumah Sakit Umum Daerah Tasikmalaya. *Jurnal Kesehatan Bakti Tunas Husada: Jurnal Ilmu-ilmu Keperawatan, Analis Kesehatan dan Farmasi*, 17(1), p. 41. doi: 10.36465/jkbth.v17i1.189.
- YASIN, H. & ISPRIYANSTI, D. 2017. Klasifikasi Data Berat Bayi Lahir Menggunakan Weighted Probabilistic Neural Network (WPNN) (Studi Kasus di Rumah Sakit Islam Sultan Agung Semarang). *Media Statistika*, 10(1), p. 61. doi: 10.14710/medstat.10.1.61-70.

Halaman ini sengaja dikosongkan