



Prediksi Perubahan Hemodinamik Pasien setelah Pemberian Premedikasi menggunakan *Machine Learning Neural Network* Guna Meningkatkan Kinerja Penanganan Medis

Jiyestha Aji Dharma Aryasa*, Aris Puji Widodo, Catur Edi Widodo

Magister Sistem Informasi, Sekolah Pascasarjana, Universitas Diponegoro, Semarang, Indonesia

Naskah masuk: 19 Januari 2024; Diterima untuk publikasi: 6 Juni 2024
DOI: 10.21456/vol14iss3pp256-266

Abstract

This research presents the development process of a machine learning neural network model for predicting hemodynamic changes in patients after premedication, aiming to enhance the performance of medical interventions. The model was constructed using 3055 patients' data who underwent premedication processes. The developed neural network model has an architecture consisting of 10 nodes in the input layer, 10 nodes in the hidden layer, and 3 nodes in the output layer. The evaluation results of the model indicate an overall accuracy of 85%. The precision values are high for normal class predictions at 0.85 and for hypertension class predictions at 0.81 with corresponding recalls of 1 (high) and 0.6 (moderate), respectively. However, predictions for the hypotension class still have a low precision of 0.6 and a recall of 0.04 (very low) due to the significantly lower number of samples in the hypotension class compared to the normal and hypertension classes. While testing with new data, the model has successfully predicted whether patients will experience hemodynamic pressure changes. It is expected that this model can contribute to improving the performance of medical interventions, thereby minimizing undesirable hemodynamic pressure changes.

Keywords: Machine Learning; Neural Network; Feedforward; Hemodynamics; Premedication.

Abstrak

Penelitian ini memaparkan proses pengembangan model *machine learning neural network* untuk prediksi perubahan hemodinamik pasien setelah premedikasi guna meningkatkan kinerja penanganan medis. Model ini dibuat dengan menggunakan 3055 data pasien yang mendapatkan proses premedikasi. Model *neural network* yang dikembangkan memiliki arsitektur yang terdiri dari 10 *node* pada *input layer*, 10 *node* pada *hidden layer*, dan 3 *node* pada *output layer*. Hasil evaluasi model menunjukkan akurasi secara umum sebesar 85%, nilai *precision* tinggi untuk hasil prediksi kelas normal sebesar 0.85 dan 0.81 untuk hasil prediksi kelas hipertensi dengan *recall* masing-masing yaitu 1 (tinggi) dan 0.6 (sedang). Namun, untuk hasil prediksi kelas hipotensi masih memiliki *precision* rendah sebesar 0.6 dan *recall* 0.04 (sangat rendah) karena sampel dari kelas hipotensi sangat sedikit jumlahnya jika dibandingkan dengan kelas normal dan kelas hipertensi. Dalam pengujian data baru, model ini telah berhasil memprediksi apakah pasien akan mengalami perubahan tekanan hemodinamik. Diharapkan model ini dapat membantu meningkatkan kinerja penanganan medis sehingga meminimalisir terjadinya perubahan tekanan hemodinamik yang tidak diinginkan.

Kata kunci: Pembelajaran Mesin; Jaringan Saraf Tiruan; *Feedforward*; Hemodinamik; Premedikasi.

1. Pendahuluan

Pada bidang kesehatan, ada suatu tahapan yang disebut dengan tahap premedikasi. Premedikasi merupakan tindakan awal anestesi dengan memberikan obat-obatan premedikasi pada pasien. Proses premedikasi ini bertujuan untuk mengubah tekanan darah pasien menuju keadaan normal yaitu antara 90/60 mmHg dan 120/80 mmHg, meredakan kecemasan berlebihan, serta mencegah mual, kejang, nyeri, atau kejadian buruk lainnya (Koshire *et al.*,

2022). Namun pemberian premedikasi yang tidak tepat dapat menimbulkan perubahan hemodinamik yang tidak sesuai pada pasien. Hemodinamik merupakan sebuah dinamika dari aliran darah. Hemodinamik ini berkaitan erat dengan distribusi tekanan dan aliran dalam sistem peredaran darah manusia (Simonneau *et al.*, 2019). Perubahan hemodinamik seperti ini sangat dihindari karena dapat memberikan pengaruh buruk jangka panjang kepada pasiennya. Pengaruh buruk tersebut contohnya seperti sulit melupakan pengalaman traumatis karena merasa sangat lemas jika tekanan darahnya turun secara

*) *Corresponding author:* jiyestha.aji@gmail.com

signifikan, atau mengalami kejang jika tekanan darahnya naik secara signifikan, gejala sulit tidur, dan rasa takut yang tidak wajar.

Machine learning adalah suatu bidang studi yang mencari penggunaan algoritma komputasi untuk mengubah data empiris menjadi model yang dapat digunakan (Janiesch *et al.*, 2021). *Machine learning* disebut sebagai sebuah cabang dari kecerdasan buatan karena memungkinkan untuk mencari makna yang berarti dari sebuah pola kejadian (Currie *et al.*, 2019). Hal ini menunjukkan bahwa *machine learning* memiliki kemampuan untuk memberikan sebuah prediksi atau pilihan menggunakan bantuan komputer dalam menyelesaikan suatu masalah. Ada banyak jenis metode dalam penerapan *machine learning*. *Neural network* merupakan salah satu jenis dari metode penerapan *machine learning* tersebut. *Neural network* atau yang lebih sering dikenal dengan sebutan Jaringan Saraf Tiruan (JST) adalah sebuah metode yang cara kerjanya terinspirasi oleh otak manusia dan dapat digunakan untuk *machine learning* dan *artificial intelligence* (Dastres and Soori, 2021). *Neural network* terdiri dari sejumlah prosesor sangat sederhana dan saling berhubungan yang disebut *neuron*. *Neuron* ini memiliki fungsi untuk mengumpulkan dan mengklasifikasikan informasi menurut arsitektur tertentu. Selain itu *neural network* juga dapat mengenali hubungan antara data dalam jumlah yang cukup besar. Dengan kelebihan yang dimilikinya, metode *neural network* dapat digunakan sebagai salah satu cara untuk menyelesaikan suatu permasalahan di banyak bidang, salah satunya di bidang kesehatan.

Sebelumnya pada Dung-Hung *et al.* (2022) telah membahas bagaimana model *machine learning* dengan pendekatan *Hemodynamic Stability Index* (HSI) dapat dijadikan sebuah cara untuk membuat prediksi dini terhadap pasien dengan jumlah 3053 data pasien *Intensive Care Unit* (ICU) yang berumur 20 tahun keatas. Hasil HSI dari penelitian Dung-Hung *et al.* (2022) mampu memprediksi 72% dari total data pasien yang menerima intervensi hemodinamik dengan spesifisitas sebesar 67%. Berdasarkan pendekatan *machine learning* yang telah dilakukan pada penelitian sebelumnya dan dengan karakteristik kelebihanannya yang mampu mengenali hubungan antara data dalam jumlah yang besar, pendekatan *machine learning* dengan metode *neural network* ini diharapkan mampu untuk membuat sebuah model prediksi yang lebih baik lagi. Hasil prediksi yang ingin dicapai pada penelitian ini adalah apakah akan terjadi perubahan tekanan hemodinamik pada seseorang setelah diberikan suatu tindakan premedikasi.

Selain itu juga, sudah ada penelitian yang sejenis seperti penelitian yang sedang dikembangkan ini, namun terdapat beberapa perbedaan yang membedakan penelitian ini dengan penelitian terdahulu. Model *deep learning* sebelumnya sudah dapat memprediksi tekanan darah pasien tiga menit ke

depan setelah dilakukan proses induksi atau proses penghilangan kesadaran pasien. Model prediksi ini dilakukan menggunakan data tanda vital pasien dan data yang terkait anestesi selama fase induksi anestesi (Jeong *et al.*, 2019). Perbedaan penelitian tersebut dengan penelitian yang akan dilakukan ini adalah jenis tindakan yang diteliti hanya pada pasien yang diberikan penanganan premedikasi. Hal ini berbeda dengan penelitian sebelumnya, karena penelitian sebelumnya meneliti tekanan darah pasien dalam tiga menit setelah dilakukan proses induksi tanpa menjelaskan apakah pasien itu mendapat proses premedikasi atau tidak. Penelitian ini juga menggunakan *machine learning* dengan algoritma *neural network feedforward* sebagai dasar penelitian yang nantinya akan memberikan prediksi apakah terjadi perubahan tekanan hemodinamik pada pasien tersebut dalam rentang waktu 10 menit setelah diberikan tindakan premedikasi.

Artikel ini memuat penelitian yang bertujuan untuk mengembangkan model *machine learning neural network feedforward* guna memprediksi perubahan hemodinamik pada pasien setelah pemberian premedikasi. Data yang digunakan adalah penggunaan data tanda vital pasien dan data terkait jenis premedikasi yang dilakukan terhadap pasien, dengan algoritma *neural network feedforward*. Model yang dikembangkan diharapkan dapat meningkatkan kinerja penanganan medis sehingga meminimalisir terjadinya perubahan tekanan hemodinamik yang tidak diinginkan.

2. Kerangka Teori

Beberapa referensi terkait teori yang mendasari penelitian ini adalah:

2.1. Machine Learning

Machine learning dapat didefinisikan sebagai studi tentang cara membuat mesin memperoleh pengetahuan baru, keterampilan baru, dan mengatur ulang pengetahuan yang ada (Letaifa, 2019). *Machine learning* juga dapat diartikan sebagai suatu bidang ilmu komputer yang memberikan kemampuan pembelajaran kepada komputer untuk mengetahui sesuatu tanpa pemrograman yang jelas. Dalam *machine learning*, ada tiga pendekatan yang sering digunakan yaitu *supervised*, *unsupervised*, dan *semi-supervised*.

Supervised learning atau pembelajaran terarah adalah salah satu metode *machine learning* dimana hasil yang diharapkan pengguna, sudah diketahui atau memiliki informasi oleh sistem. Hal ini berarti bahwa metode pembelajaran ini bekerja dengan memanfaatkan kembali data dan hasil output yang pernah dimasukkan oleh pengguna atau dikerjakan oleh sistem sebelumnya. *Supervised learning* memerlukan pemahaman dari manusia untuk mencapai hasil melalui suatu proses pembelajaran

(Yakimovich *et al.*, 2021). Pada metode ini, pola *input* dan pola *output* dibutuhkan untuk mengenali suatu informasi dalam bank memori. Ketika suatu pola *input* dibentuk, sistem akan meneruskan rangsangan data hingga ke bank memori dan sistem *output*. Sistem *output* yang menerima rangsangan data akan menampilkan pola *output* dan membandingkan polanya dengan pola *input*. Jika pola cocok, data akan ditampilkan dari bank memori dalam bentuk *output*. Apabila pola *input* dan pola *output* tidak ada yang cocok, maka *output* akan *error*. Dan jika nilai *error* cukup besar, pembelajaran lebih lanjut perlu dilakukan. Beberapa contoh algoritma yang sering digunakan dalam supervised learning adalah *Decision Tree*, *Naive Bayes*, dan Jaringan Saraf Tiruan (*Neural Network*).

Unsupervised learning atau pembelajaran tidak terarah merupakan sebuah metode *machine learning*, dimana pada metode ini hasil yang diharapkan tidak dapat diketahui oleh siapapun. Dengan kata lain, hasil yang akan ditampilkan hanya bergantung kepada nilai bobot yang disusun pada awal pembangunan sistem dan tentu masih dalam ruang lingkup tertentu. *Unsupervised learning* tidak secara langsung memberikan jawaban yang tepat, namun metode ini memberikan sebuah model bagi penggunaannya untuk menemukan sebuah informasi baru dari data tersebut (El Bouchefry and De Souza, 2020). Tujuan utama dari metode pembelajaran ini adalah agar para penggunaannya dapat mengelompokkan objek-objek yang dinilai sejenis dalam ruang atau area tertentu. Metode pembelajaran ini sangat cocok digunakan untuk mencari atau mengelompokkan suatu pola dari banyak objek sejenis yang tidak sepenuhnya sama. Beberapa contoh algoritma yang sering digunakan dalam unsupervised learning adalah algoritma *K-Nearest Neighbor*, *K-means Clustering*, dan *Fuzzy Clustering*.

Ada beberapa hal yang dapat digunakan untuk membedakan algoritma *supervised* dan *unsupervised learning*. Jika dilihat dari segi data *input*, *unsupervised learning* membutuhkan data latih dalam proses membangun sebuah model dan menentukan model terbaik sedangkan *unsupervised learning* tidak membutuhkan data latih dan tanpa label. Lalu dari segi akurasi, algoritma *supervised learning* lebih akurat karena menggunakan model dengan *error* paling kecil, sedangkan algoritma *unsupervised learning* kurang akurat karena tidak ada data label untuk memverifikasi hasil.

Dan yang terakhir, *semi-supervised learning* merupakan sebuah algoritma yang mengkombinasikan *supervised learning* dan *unsupervised learning*, dimana sampel-sampel *input* yang diberikan ada yang berlabel dan ada yang tidak berlabel. Algoritma ini akan membangkitkan suatu fungsi yang tepat berdasarkan semua *input* yang diberikan.

2.2. Neural Network

Neural network atau yang lebih sering dikenal dengan sebutan Jaringan Syaraf Tiruan adalah sebuah metode yang cara kerjanya terinspirasi oleh otak manusia dan dapat digunakan untuk *machine learning* dan *artificial intelligence* (Dastres and Soori, 2021). *Neural network* terdiri dari sejumlah prosesor sangat sederhana dan saling berhubungan yang disebut *neuron*. *Neuron* ini memiliki fungsi untuk mengumpulkan dan mengklasifikasikan informasi menurut arsitektur tertentu. Selain itu *neural network* juga dapat mengenali hubungan antara data dalam jumlah yang cukup besar. *Neural network* juga dapat didefinisikan sebagai kombinasi paralel secara masif dari unit pemrosesan sederhana yang dapat memperoleh pengetahuan dari lingkungannya, melalui proses pembelajaran dan menyimpan pengetahuan dalam aktivitasnya.

Neural Network adalah suatu usaha untuk meniru fungsi otak manusia. Otak manusia diyakini terdiri dari jutaan unit pengolahan kecil yang disebut *neuron*, yang bekerja secara paralel. Neuron saling terhubung satu sama lain melalui koneksi neuron. Setiap individu *neuron* mengambil *input* dari satu set *neuron*, lalu memproses *input* tersebut dan melewati *output* untuk satu set *neuron*. Kemudian *output* dikumpulkan oleh *neuron* lain untuk diproses lebih lanjut.

2.3. Premedikasi

Premedikasi adalah suatu tahapan pemberian obat pada seorang pasien. Premedikasi diberikan kepada pasien dengan tujuan antara lain untuk menstabilkan tekanan darah dan laju nadi dari pasien tersebut. Proses premedikasi ini juga bertujuan untuk mengubah tekanan darah pasien menuju keadaan normal yaitu diantara 90/60 mmHg dan 120/80 mmHg, meredakan kecemasan berlebihan pada pasien, serta mencegah mual, kejang, nyeri, atau kejadian buruk lainnya (Koshire *et al.*, 2022).

Premedikasi dilakukan dengan cara memberikan obat yang umumnya diberikan melalui suntikan. Dalam prosesnya, premedikasi memakai dua kelompok obat utama obat. Pertama adalah obat opiate seperti fentanil yang secara kimiawi terkait dengan morfin. Obat ini bekerja pada sistem saraf pusat, menekan kesadaran akan rasa sakit dan membuat penderita merasa senang dan santai. Kelompok kedua mencakup senyawa seperti atropin dan skopolamin. Ini serupa dengan substansi yang ada dalam tanaman mematikan, nightshade. Obat ini bekerja pada perifer tubuh di ujung saraf tertentu, dan menyebabkan penurunan aktivitas kelenjar kecil yang melapisi mulut dan saluran udara, dan kelenjar ludah.

2.4. Hemodinamik

Hemodinamik atau hemodinamika adalah dinamika dari aliran darah. Hemodinamik memberikan respon secara terus menerus memonitor dan menyesuaikan dinamika aliran darah dengan

kondisi di dalam tubuh dan lingkungannya. Dengan demikian hemodinamik adalah suatu hal yang mengatur aliran darah dalam pembuluh darah. Dalam konteks medis, istilah hemodinamik merujuk pada ukuran dasar fungsi kardiovaskular, seperti tekanan arteri atau curah jantung (Simonneau *et al.*, 2019). Perubahan hemodinamik pada seseorang dipengaruhi oleh beberapa faktor, salah satunya adalah aktifitas tubuh atau kegiatan tubuh orang tersebut. Aktifitas tubuh ini meliputi aktifitas tidur, kecemasan yang berlebihan, tekanan darah, faktor usia, berat badan, faktor stress dan juga kondisi psikis dari orang tersebut.

2.5. Hipertensi

Hipertensi atau tekanan darah tinggi adalah suatu keadaan dimana seseorang mengalami peningkatan tekanan darah di atas normal dalam waktu yang cukup lama. Hipertensi juga bisa diartikan sebagai suatu kondisi ketika seseorang mempunyai tekanan darah sistolik diatas 120 mm dan tekanan darah diastolik diatas 80 Hg atau dapat dituliskan diatas 120/80 mmHg. Kategori pengukuran hipertensi dapat dibagi menjadi empat yaitu pertama adalah tekanan darah normal. Tekanan darah normal pada manusia didefinisikan jika tekanan darahnya berada di bawah 120/80 mm Hg. Kemudian, kategori prahipertensi merupakan sebuah kondisi tekanan sistolik seseorang berkisar antara 120-139 mm Hg, atau tekanan darah diastoliknya berkisar antara 80-89 mm Hg. Prahipertensi ini cenderung memburuk dari waktu ke waktu, setelah seseorang mengalami prahipertensi ini. Lalu kategori berikutnya, hipertensi tahap 1 merupakan kategori tekanan sistolik seseorang berkisar antara 140-159 mm Hg, atau tekanan diastoliknya berkisar antara 90-99 mm Hg. Terakhir kategori hipertensi tahap 2, kategori ini tergolong paling parah, karena pada kategori ini, tekanan sistolik seseorang telah mencapai 160 mm Hg atau lebih tinggi, atau tekanan diastoliknya telah mencapai 100 mm Hg atau lebih tinggi. Kondisi ini jika tidak segera ditangani, dapat menjurus ke berbagai masalah kesehatan lainnya, seperti stroke dan penyakit jantung (Simonneau *et al.*, 2019).

Secara umum, penyebab hipertensi dibagi menjadi hipertensi primer dan hipertensi sekunder. Hipertensi primer menyerang 90% penderita hipertensi. Penyebabnya tidak diketahui dengan pasti dan cenderung terjadi bertahap selama bertahun-tahun. Hipertensi ini diduga terjadi akibat faktor gaya hidup seseorang dan juga faktor genetik seseorang tersebut. Sedangkan hipertensi sekunder merupakan hipertensi yang diketahui penyebabnya, ini terjadi pada 5-10% penderita hipertensi. Hipertensi ini biasanya muncul tiba-tiba dan menyebabkan tekanan darah yang lebih tinggi daripada hipertensi primer. Beberapa kondisi dan obat-obatan yang dapat menyebabkan hipertensi sekunder antara lain sleep apnea, masalah ginjal, tumor kelenjar adrenal, masalah tiroid, cacat bawaan

dalam pembuluh darah, dan obat-obatan tertentu seperti obat KB, obat flu, dan juga obat anti nyeri.

2.6. Hipotensi

Tekanan darah normal berkisar antara 90/60 mmHg dan 120/80 mmHg. Ketika tekanan darah berada di bawah rentang tersebut, maka seseorang dapat dikatakan menderita hipotensi. Hipotensi juga bisa diartikan kondisi ketika tekanan darah seseorang terukur berada di bawah 90/60 mmHg. Kondisi hipotensi atau darah rendah berisiko menimbulkan gejala seperti pusing, lemas, pandangan buram, konsentrasi berkurang, sesak napas, mual dan muntah, bahkan bisa menyebabkan pingsan (Simonneau *et al.*, 2019).

Tekanan darah dapat berubah sepanjang waktu, tergantung kondisi dan aktivitas yang dilakukan tiap orang. Kondisi ini merupakan hal yang normal, karena tekanan darah dipengaruhi oleh banyak faktor, termasuk penambahan usia dan keturunan. Tidak hanya pada orang dewasa, tekanan darah rendah juga bisa terjadi pada anak-anak. Hipotensi juga bisa disebabkan oleh kondisi atau penyakit tertentu, seperti kehamilan, ketidakseimbangan hormon, dehidrasi, infeksi, penyakit jantung, pendarahan, kekurangan nutrisi, dan juga ketika sedang mengonsumsi obat-obatan tertentu.

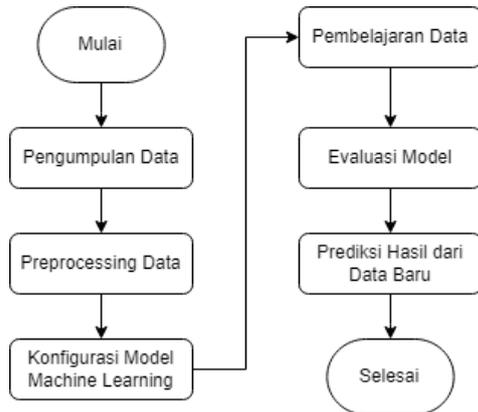
Pengobatan hipotensi ditentukan berdasarkan penyebab yang mendasarinya. Jika hipotensi disebabkan oleh konsumsi obat-obatan tertentu, dokter akan mengurangi dosisnya, atau mengganti jenis obat bila perlu. Tujuan pengobatannya adalah untuk meningkatkan tekanan darah, meredakan gejala yang muncul, dan mengobati kondisi yang menyebabkan hipotensi.

Hipotensi juga dapat ditangani dengan melakukan perubahan pola makan dan gaya hidup. Hal yang dapat dilakukan untuk memulai perubahan pola makan dan gaya hidup ini yaitu, memperbanyak konsumsi makanan dengan kadar garam tinggi, karena garam dapat meningkatkan tekanan darah. Kemudian dapat memperbanyak konsumsi cairan, karena cairan dalam tubuh manusia dapat meningkatkan volume darah dan membantu mencegah dehidrasi. Berolahraga secara teratur untuk meningkatkan tekanan darah dan kesehatan jantung.

3. Metode

Metode dalam penelitian dibagi menjadi beberapa proses, dimulai dari proses pengumpulan data, lalu melakukan proses pembelajaran data, jika semua data sudah dipelajari oleh *machine learning* ini, maka akan dilanjutkan ke proses pengujian dan evaluasi model, hasil dari pengujian dan evaluasi ini akan dijadikan acuan dalam memberikan hasil prediksi dari data pasien baru yang ingin diprediksi hasilnya, apakah nantinya pasien tersebut diprediksi akan mengalami perubahan tekanan hemodinamik atau tidak setelah

melakukan proses premedikasi. Alur tahapan dari penelitian ini dapat dilihat pada Gambar 1.



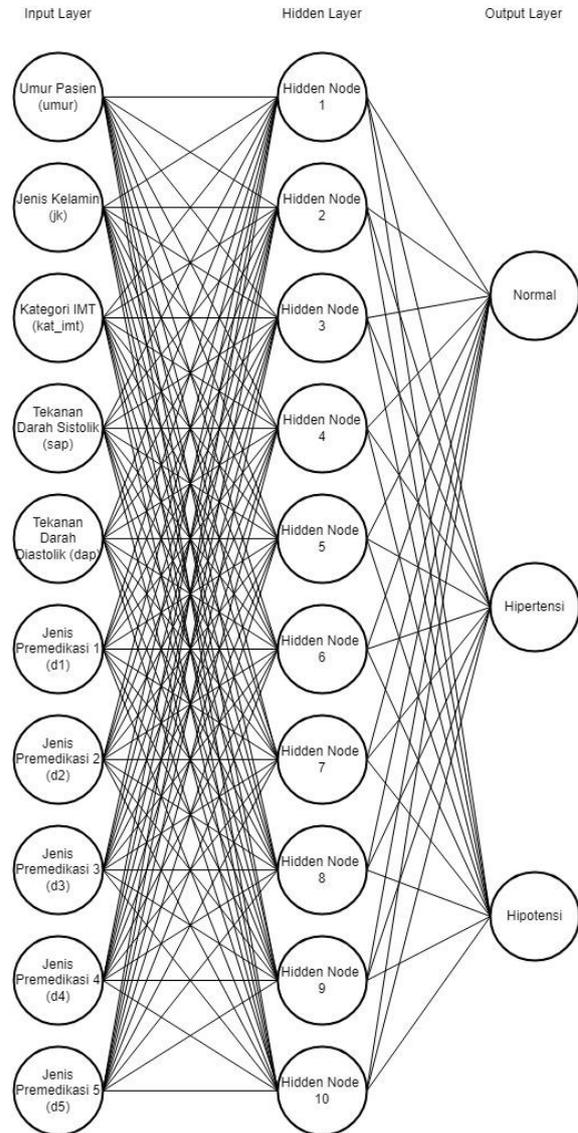
Gambar 1. Diagram alir tahapan penelitian

Pada tahap pengumpulan data dilakukan proses pengumpulan data yang relevan untuk proses penelitian. Penelitian ini bersifat penelitian kuantitatif. Tahap pengumpulan data pada penelitian ini dibagi menjadi dua tahapan, yaitu tahap perizinan penelitian dan tahap pengumpulan data pasien. Pertama pada tahap perizinan penelitian, akan melakukan proses perizinan dengan salah satu pegawai atau bagian di RSUD Sanglah Denpasar, Bali yang berwenang dalam proses pengumpulan data mengenai pasien khususnya pasien premedikasi. Tujuan dari dilakukannya proses perizinan ini untuk meminta izin agar data pasien yang didapatkan nantinya, dapat digunakan pada proses penelitian ini. Kemudian, tahap pengumpulan data. Pada tahapan ini akan dilakukan pengumpulan data pasien RSUD Sanglah Denpasar, Bali yang mendapatkan proses premedikasi pada tahun 2023. Data ini nantinya akan dijadikan sebagai data latih dan data uji pada tahap penelitian berikutnya.

Kemudian penelitian dilanjutkan ke tahap pembelajaran. Tahap ini merupakan tahapan *machine learning* mempelajari data yang sudah diperoleh dari proses pengumpulan data sebelumnya. Penelitian ini akan menggunakan *neural network feedforward* dalam proses pembelajarannya. *Neural network feedforward* adalah sebuah *neural network* yang memiliki *multilayer perceptron*, dimana *perceptron* ini akan memiliki fungsi seperti pada satu buah neuron. Aliran informasi pada *neural network feedforward* ini akan berjalan dari *input layer* menuju *output* secara satu arah tanpa adanya sebuah siklus, sebuah pembalikan arah, atau sebuah pengulangan (Urso et al., 2019).

Neural network feedforward terdiri dari tiga layer utama, yaitu *Input Layer*, *Hidden Layer*, dan yang terakhir *Output Layer* (Xie et al., 2022). *Input layer* merupakan sebuah layer yang berisi data *input* awal untuk *neural network*. *Hidden layer* merupakan sebuah layer yang berada diantara *input* dan *output* layer, semua proses komputasi terjadi pada *layer* ini.

Output layer merupakan *layer* yang berfungsi untuk menyediakan hasil dari proses. Berikut merupakan contoh rancangan struktur *neural network feedforward* pada penelitian ini, dapat dilihat pada Gambar 2.



Gambar 2. Neural Network Feedforward

Sebelum dilakukannya tahap pembelajaran, data yang sudah diperoleh pada proses sebelumnya akan mengalami proses *preprocessing* data. Hal ini mencakup memberikan label pada data dan juga normalisasi data. Kemudian data yang telah siap untuk dimasukkan ke model, dibagi menjadi dua jenis, *input* variabel dan *output* variabel. Terdapat 10 *input nodes* pada *input layer* di penelitian ini, hal ini mewakili 10 *input* variabel yang akan digunakan oleh model untuk membuat prediksi. Variabel *input* tersebut adalah umur pasien (umur), jenis kelamin (jk), kategori IMT (kat_imt), tekanan darah sistolik (sap), tekanan darah diastolik (dap), 5 jenis premedikasi yang dilakukan

pada pasien (d1, d2, d3, d4, dan d5). Kemudian untuk *output layer*, penelitian ini memiliki satu variabel *output* yaitu variabel hasil prediksi yang dibagi menjadi tiga *output nodes*, masing-masing *node* ini mewakili hasil dari kondisi pasien setelah mendapat proses premedikasi. Tiga *nodes* tersebut adalah normal, hipotensi, dan hipertensi. Kemudian untuk jumlah *node* pada *hidden layer*, akan dilakukan eksperimen untuk mendapatkan jumlah yang optimal agar mendapatkan hasil yang terbaik dari *machine learning* ini. Model terbaik yang didapatkan pada tahapan ini akan dilanjutkan untuk diuji dan dievaluasi.

Pengujian dan evaluasi merupakan tahapan untuk menguji dan mengevaluasi model yang telah didapatkan dari proses pembelajaran data. Tujuan dilakukannya tahap ini adalah untuk menguji akurasi, *precision*, dan juga *recall* dari model yang dihasilkan dari proses pembelajaran. Jika hasil evaluasi dapat dengan benar mengkategorikan data dan juga memiliki nilai akurasi yang dapat diterima, maka tahap pengujian ini sudah menghasilkan sebuah model prediksi yang dapat digunakan untuk proses prediksi hasil perubahan tekanan hemodinamik dari pasien yang telah mendapat proses premedikasi.

Kemudian model prediksi yang sudah didapatkan dari tahap pengujian ini, akan digunakan untuk memprediksi hasil dari data baru. Proses ini akan menghasilkan sebuah prediksi apakah pasien tersebut akan mengalami perubahan tekanan hemodinamik dengan kategori normal, hipertensi, atau hipotensi. Hasil prediksi ini dibuat berdasarkan dengan model prediksi yang telah dipelajari, dievaluasi, dan diuji sebelumnya.

4. Hasil dan Pembahasan

Dalam bagian ini akan menjelaskan mengenai perangkat penelitian, basis data dalam penelitian, *preprocessing* data, pembelajaran data, pengujian dan evaluasi model, beserta prediksi data baru.

4.1. Perangkat Penelitian

Penelitian ini dibuat menggunakan perangkat keras berupa komputer dengan sistem operasi *Windows 10*, kemudian menggunakan *Python 3.10* sebagai bahasa pemrograman dan *Jupyter Notebook* sebagai *text editor*. Terdapat lima *Library* yang digunakan pada penelitian ini. Kelima *library Python* ditampilkan pada Tabel 1.

Tabel 1. *Library python*

Nama Library	Fungsi
Pandas	Manipulasi dan analisis data
NumPy	Melakukan operasi numerik dan ilmiah seperti matriks, aljabar, dan statistik
Keras	API yang digunakan untuk perhitungan <i>machine learning</i>

Nama Library	Fungsi
Sklearn	Menyediakan algoritma dan model perhitungan untuk <i>supervised learning</i> dan <i>unsupervised learning</i>
Tensorflow	Membuat algoritma dan model <i>machine learning</i>
Matplotlib	Membuat visualisasi data dalam bentuk grafik

4.2. Basis Data

Basis data yang digunakan pada penilitan ini merupakan data pasien yang mendapatkan proses premedikasi di *RSU Sanglah Denpasar* pada tahun 2023. Data yang dikumpulkan terdiri dari umur pasien, jenis kelamin, berat badan, tinggi badan, tekanan darah sistolik, tekanan darah diastolik, kategori premedikasi yang dilakukan, dan kondisi tekanan darah pasien setelah 10 menit proses premedikasi dilakukan.

4.3. Preprocessing Data

Preprocessing data merupakan tahap persiapan data sebelum data tersebut dimasukkan ke dalam suatu model dalam tahap pembelajaran data. Proses pembelajaran dan prediksi data akan lebih efektif dilakukan jika seluruh data disiapkan dalam bentuk data numerik. Maka dari itu, langkah pertama yang dilakukan pada *preprocessing* data ini adalah memberikan label pada data jenis kelamin pasien. Data jenis kelamin pasien akan diberikan label 1 jika pasien tersebut laki-laki dan diberikan label 2 jika pasien tersebut perempuan.

Selanjutnya, berat dan tinggi badan pasien akan diubah menjadi Indeks Massa Tubuh (*IMT*). Nilai *IMT* didapatkan dari Persamaan (1).

$$IMT = \frac{\text{Berat badan}}{(\text{Tinggi badan})^2} \quad (1)$$

Nilai *IMT* yang sudah didapatkan dari Persamaan (1) akan dibagi menjadi 5 kategori. Kategori ini diklasifikasikan sesuai dengan klasifikasi nasional menurut Kementerian Kesehatan Republik Indonesia yang ditampilkan pada Tabel 2.

Tabel 2. Kategori *IMT*

Kategori	Klasifikasi	IMT
1	Kekurangan berat badan tingkat berat	< 17,0
2	Kekurangan berat badan tingkat ringan	17,0 – 18,4
3	Normal	18,5 – 25,0
4	Kelebihan berat badan tingkat ringan	25,1 – 27,0
5	Kelebihan berat badan tingkat berat	≥ 27,0

Terdapat lima kategori premedikasi yang paling sering digunakan pada *RSU Sanglah, Denpasar*. Kelima kategori premedikasi tersebut diberikan label d1, d2, d3, d4, dan d5 dengan *value* 0 jika pasien tidak mendapatkan penanganan kategori premedikasi

tersebut, dan 1 jika pasien mendapatkan penanganan kategori premedikasi tersebut.

Kondisi tekanan darah pasien setelah mendapatkan premedikasi akan diberikan label 0 jika tekanan darah pasien normal, 1 jika pasien mengalami hipertensi, dan 2 jika pasien mengalami hipotensi.

Setelah melalui proses pengumpulan data, didapatkan 3055 data pasien yang sebelumnya juga sudah melalui proses preprocessing data dan sudah dapat digunakan untuk proses pembelajaran data menggunakan *machine learning neural network feedforward*. Contoh data pasien yang telah melalui tahap *preprocessing*, dapat dilihat pada Tabel 3.

Tabel 3. Data pasien

No	Umur	JK	Tinggi	Berat	Kat_IMT	SAP	DAP	d1	d2	d3	d4	d5	Result
1	33	2	160	60	3	110	60	0	0	0	1	1	0
2	49	2	165	45	1	110	80	1	0	0	1	0	0
3	27	2	165	65	3	110	70	1	0	0	1	1	0
4	40	2	155	35	1	100	70	1	0	0	1	1	2
5	58	2	160	60	3	146	96	0	0	0	1	1	1
6	49	2	145	45	2	125	83	1	0	0	1	0	2
7	58	2	155	45	2	150	80	1	0	0	1	1	1
8	60	1	170	55	2	140	90	1	0	0	1	1	2
9	36	2	155	50	2	110	69	1	0	0	1	1	2
10	17	2	160	50	2	121	76	1	1	1	1	1	2

4.4. Pembelajaran Data

Proses pembelajaran data dimulai dengan tahap normalisasi data. Proses normalisasi ini dilakukan dengan tujuan untuk mengubah nilai kolom numerik dalam himpunan data untuk menggunakan skala umum, tanpa mendistorsi perbedaan dalam rentang nilai atau kehilangan informasi. Pada penelitian ini, proses normalisasi dilakukan dengan bantuan Sklearn melalui fungsi *Standart Scaler*.

Kemudian proses dilanjutkan dengan memisahkan data latih dan data uji dengan rasio 80 persen data latih dan 20 persen data uji. Pemisahan data latih dan data uji ini dilakukan secara acak tanpa ada pola pemisahan tertentu. Setelah data latih dan data uji sudah dipisahkan, dilakukan pembuatan model *machine learning neural network*.

Model ini memerlukan *input layer*, *hidden layer*, dan *output layer*. Terdapat 10 *nodes* di *input layer* pada penelitian ini, yang mewakili 10 variabel *input* yang akan digunakan oleh model untuk membuat prediksi. Variabel *input* tersebut adalah umur, jk, kat_imt, sap, dap, d1, d2, d3, d4, dan d5. Kemudian untuk *output layer*, penelitian ini memiliki tiga *nodes*, masing-masing *nodes* ini mewakili kondisi pasien setelah mendapat proses premedikasi. Kondisi tersebut adalah normal, hipotensi, dan hipertensi. Terakhir untuk jumlah *nodes* pada *hidden layer*, ditentukan dengan cara mencari perbandingan akurasi dan *loss* dari beberapa *hidden nodes* yang akan dicoba. Pada penelitian ini akan mencoba membandingkan nilai akurasi dan *loss* dari model dengan 10 *hidden nodes*, 20 *hidden nodes*, dan 40 *hidden nodes*. Hasil perbandingan akurasi dan *loss* model ditampilkan pada Tabel 4.

Tabel 4. Perbandingan akurasi dan *loss*

Model	Loss	Akurasi
10 – 10 – 3	0.4470	0.8494

Model	Loss	Akurasi
10 – 20 – 3	0.4398	0.8478
10 – 40 – 3	0.4621	0.8494

Berdasarkan hasil perbandingan akurasi dan *loss* diatas, maka dipilihlah model dengan 10 *input nodes*, 10 *hidden nodes*, dan 3 *output nodes*. Kemudian untuk epoch dan batch, dilakukan percobaan evaluasi model dengan 10 – 10 – 3 menggunakan 50 *epoch*, 100 *epoch*, dan 200 *epoch*, dengan 32 *batch*, 64 *batch*, dan 128 *batch*. Tabel 5., Tabel 6., dan Tabel 7. merupakan tabel perbandingan akurasi dan *loss* dari setiap percobaan *epoch* dan *batch* yang sudah dilakukan.

Tabel 5. Perbandingan *epoch* 50

Batch	Loss	Akurasi
32	0.4470	0.8494
64	0.4439	0.8462
128	0.4800	0.8363

Tabel 6. Perbandingan *epoch* 100

Batch	Loss	Akurasi
32	0.4398	0.8511
64	0.4593	0.8494
128	0.4411	0.8478

Tabel 7. Perbandingan *epoch* 200

Batch	Loss	Akurasi
32	0.4731	0.8445
64	0.4517	0.8494
128	0.4540	0.8462

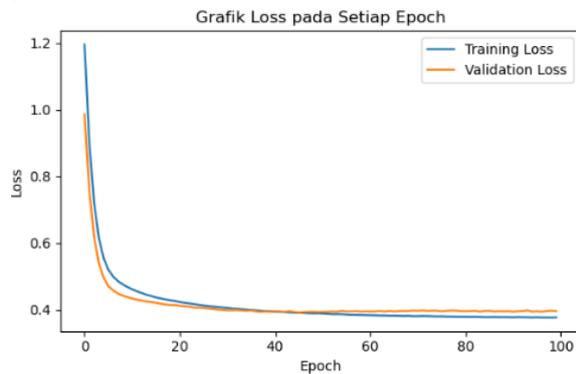
Percobaan dengan menggunakan 100 *epoch* dengan 32 *batch* mendapatkan hasil akurasi tertinggi dengan *loss* terendah dibandingkan dengan percobaan lain yang telah sebelumnya dilakukan. Hasil dari percobaan ini dapat dilihat pada Gambar 3.

```

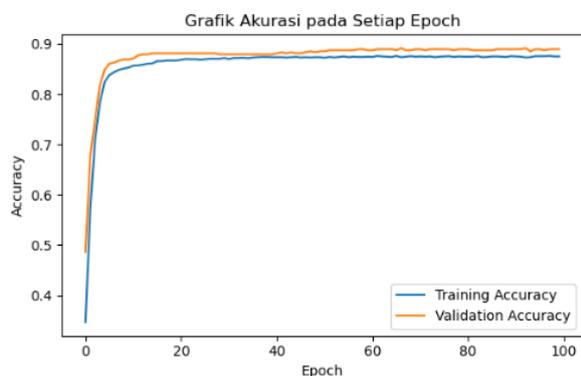
Epoch 96/100
62/62 [=====] - 0s 3ms/step
896
Epoch 97/100
62/62 [=====] - 0s 2ms/step
875
Epoch 98/100
62/62 [=====] - 0s 2ms/step
896
Epoch 99/100
62/62 [=====] - 0s 2ms/step
896
Epoch 100/100
62/62 [=====] - 0s 3ms/step
896
20/20 [=====] - 0s 2ms/step
Akurasi pada data uji: 85.11%
loss pada data uji: 43.98%
    
```

Gambar 3. Hasil percobaan 100 epoch dan 32 batch

Grafik akurasi dan *loss* dari percobaan 100 epoch dan 32 batch dapat dilihat pada Gambar 4. dan Gambar 5.



Gambar 4. Grafik Loss 100 epoch dan 32 batch



Gambar 5. Grafik Akurasi 100 epoch dan 32 batch

Setelah melalui proses pembuatan dan evaluasi model ini, proses pembelajaran ini telah menghasilkan sebuah model *machine learning neural network feedforward* dengan 10 *input nodes*, 10 *hidden nodes*, 3 *output nodes*, yang dievaluasi dengan 100 epoch dan 32 batch dengan hasil akurasi sebesar 85,11%.

4.5. Pengujian dan Evaluasi Model

Proses ini dilakukan dengan cara menguji dan mengevaluasi beberapa hal dari model yang telah

dibuat. Evaluasi pertama adalah akurasi model, dihitung dengan menggunakan fungsi `predict(x_uji)` sehingga menghasilkan akurasi sebesar 85%.

Kemudian evaluasi dilanjutkan dengan menghitung matriks konfusi berdasarkan prediksi model dan nilai sebenarnya dari dataset uji. Perhitungan ini dilakukan dengan cara `confusion_matrix(y_uji, y_pred)`. Berikut hasil dari evaluasi matriks konfusi ini dapat dilihat pada Gambar 6.

```

Confusion Matrix:
[[495  0  2]
 [ 14 22  0]
 [ 70  5  3]]
    
```

Gambar 6. Evaluasi matriks konfusi

Hal ini menjelaskan pada baris pertama (*True Class 0*): Dari 497 sampel yang sebenarnya adalah kelas 0 (normal), model dengan benar memprediksi 495 di antaranya sebagai kelas 0, salah memprediksi 2 sebagai kelas 2. Kemudian pada baris kedua (*True Class 1*): Dari 36 sampel yang sebenarnya adalah kelas 1 (hipertensi), model dengan benar memprediksi 22 di antaranya sebagai kelas 1, dan salah memprediksi 14 sebagai kelas 0. Terakhir pada baris ketiga (*True Class 2*): Dari 78 sampel yang sebenarnya adalah kelas 2 (hipotensi), model dengan benar memprediksi 3 di antaranya sebagai kelas 2, salah memprediksi 70 sebagai kelas 0, dan salah memprediksi 5 sebagai kelas 1.

Kemudian evaluasi terakhir adalah untuk mengetahui laporan klasifikasi dari model ini. Berikut hasil laporan klasifikasi yang dihitung dengan menggunakan fungsi `classification_report(y_uji, y_pred)`. Berikut hasil dari fungsi laporan klasifikasi dengan menggunakan model ini dapat dilihat pada Gambar 7.

```

Classification Report:
              precision    recall  f1-score   support

     0           0.85         1.00         0.92         497
     1           0.81         0.61         0.70          36
     2           0.60         0.04         0.07          78

 accuracy          0.85         0.85         0.85         611
 macro avg         0.76         0.55         0.56         611
 weighted avg         0.82         0.85         0.80         611
    
```

Gambar 7. Laporan klasifikasi

Berdasarkan laporan klasifikasi pada Gambar 7., dapat diambil beberapa informasi baru. Mulai dari *precision*, disini berfungsi untuk mengukur seberapa akurat model ketika memprediksi kelas tertentu. Untuk kelas 0 (normal), *precision* tinggi (0.85), yang berarti sebagian besar prediksi 0 yang dibuat oleh model adalah benar. Kemudian untuk kelas 1 (hipertensi), *precision* sedang (0.81), yang menunjukkan bahwa dari prediksi 1 yang dibuat,

sebagian besar benar. Terakhir untuk kelas 2 (hipotensi), *precision* rendah (0.60), yang menunjukkan bahwa model cenderung membuat banyak kesalahan dengan memprediksi kelas 2. Selanjutnya, *recall* berfungsi untuk mengukur sejauh mana model dapat menemukan semua kelas yang sebenarnya. Untuk kelas 0, *recall* sangat tinggi (1.00), yang berarti model dapat menemukan sebagian besar sampel kelas 0. Kemudian untuk kelas 1, *recall* sedang (0.61), yang menunjukkan bahwa model kurang baik dalam menemukan semua sampel kelas 1. Terakhir, untuk kelas 2, *recall* sangat rendah (0.04), menunjukkan bahwa model hampir tidak mampu menemukan sampel kelas 2. Berikutnya, *F1-score* adalah rata-rata harmonik dari *precision* dan *recall*. Untuk kelas 0, *F1-score* tinggi (0.92), yang menunjukkan keseimbangan yang baik antara *precision* dan *recall*. Untuk kelas 1, *F1-score* sedang (0.70), menunjukkan keseimbangan yang lebih rendah antara *precision* dan *recall*. Untuk kelas 2, *F1-score* sangat rendah (0.07), menunjukkan bahwa model memiliki kinerja buruk pada kelas 2. *Support* menjelaskan berapa banyak sampel yang mendukung tiap kelas, pada model ini ada 497 sampel untuk kelas 0, 36 sampel untuk kelas 1, dan 78 sampel untuk kelas 2. Dan terakhir kemampuan evaluasi dari model ini menunjukkan nilai 85%. Hasil ini didapat dari jumlah prediksi yang benar dari keseluruhan sampel dibagi dengan total sampel.

Sebelumnya pada Dung-Hung *et al.* (2022) telah membahas bagaimana model *machine learning*

dengan pendekatan *Hemodynamic Stability Index* (HSI) dapat dijadikan sebuah cara untuk membuat prediksi dini terhadap pasien dengan jumlah 3053 data pasien *Intensive Care Unit* (ICU) yang berumur 20 tahun keatas. Hasil HSI dari penelitian Dung-Hung *et al.* (2022) mampu memprediksi 72% dari total data pasien yang menerima intervensi hemodinamik dengan spesifisitas sebesar 67%. Jika dibandingkan dengan penelitian ini, penelitian ini menggunakan 3055 data pasien dengan umur 17 tahun keatas yang mendapatkan penanganan premedikasi dengan cara pendekatan pembuatan model *machine learning neural network feedforward* untuk memprediksi perubahan hemodinamik dari pasien dengan hasil prediksi keseluruhan 85%. Kemudian untuk *precision* dari penelitian ini, mendapatkan hasil 0,85 untuk kelas normal, 0,81 untuk kelas hipertensi, dan 0,6 untuk kelas hipotensi.

4.6. Prediksi Data Baru

Proses ini dilakukan dengan cara memberikan input data baru kedalam model yang telah dibuat sebelumnya. Setelah data baru diinputkan maka *machine learning* akan memproses data tersebut dan membuat hasil prediksi apakah pasien akan dalam kondisi normal, hipotensi, atau hipertensi setelah mendapat premedikasi. Berikut merupakan data baru yang akan diuji dalam penelitian ini, dapat dilihat pada Tabel 8.

Tabel 8. Data baru

No	Umur	JK	Tinggi	Berat	Kat_IMT	SAP	DAP	d1	d2	d3	d4	d5	Result
1	53	2	160	65	4	130	80	1	0	0	0	0	0
2	58	2	160	60	3	120	80	0	0	0	0	0	0
3	57	1	165	60	2	110	70	1	0	0	1	0	0
4	71	2	150	40	1	130	80	1	0	0	1	0	0
5	58	2	160	60	3	146	96	0	0	0	1	1	1
6	71	2	169	60	2	172	73	1	0	0	1	0	1
7	50	2	160	58	2	140	90	1	0	0	1	0	1
8	51	2	155	56	3	156	91	1	0	0	1	1	2
9	29	2	155	45	2	106	66	1	0	0	1	1	2
10	69	2	150	60	4	156	92	1	0	0	1	1	2

Dengan menggunakan data baru pada Tabel 8., dilakukan prediksi hasil menggunakan model yang telah dievaluasi sebelumnya. Dari 10 data baru diambil acak data no 1, 5, dan 9 untuk diuji hasil prediksinya.

Dapat dilihat pada Gambar 8., data no 1 dari Tabel 8., pasien dengan umur 53, berjenis kelamin perempuan, termasuk dalam kategori IMT 4, dengan tekanan darah sistolik 130 mmHg, tekanan darah diastolik 80 mmHg, yang mendapatkan premedikasi jenis d1, menghasilkan prediksi normal dari yang seharusnya normal.

```
1/1 [=====] - 0s 23ms/step
Hasil Prediksi untuk Data Baru: 0
0 : Normal, 1 : Hipertensi, 2 : Hipotensi
```

Gambar 8. Hasil prediksi data no. 1

Kemudian pada Gambar 9., data no 5 dari Tabel 8., pasien dengan umur 58, berjenis kelamin perempuan, termasuk dalam kategori IMT 3, dengan tekanan darah sistolik 146 mmHg, tekanan darah diastolik 96 mmHg, yang mendapatkan premedikasi jenis d4 dan d5, menghasilkan prediksi hipertensi dari yang seharusnya hipertensi.

```
1/1 [=====] - 0s 23ms/step  
Hasil Prediksi untuk Data Baru: 1  
0 : Normal, 1 : Hipertensi, 2 : Hipotensi
```

Gambar 9. Hasil prediksi data no. 5

Terakhir, pada Gambar 10., data no 9 dari Tabel 8., pasien dengan umur 29, berjenis kelamin perempuan, termasuk dalam kategori IMT 2, dengan tekanan darah sistolik 106 mmHg, tekanan darah diastolik 66 mmHg, yang mendapatkan premedikasi jenis d1, d4, dan d5, menghasilkan prediksi normal dari yang seharusnya hipotensi.

```
1/1 [=====] - 0s 26ms/step  
Hasil Prediksi untuk Data Baru: 0  
0 : Normal, 1 : Hipertensi, 2 : Hipotensi
```

Gambar 10. Hasil prediksi data no. 9

Pada Dung-Hung *et al.* (2022) telah membahas bagaimana model *machine learning* dengan pendekatan *Hemodynamic Stability Index* (HSI) dapat dijadikan sebuah cara untuk membuat prediksi dini terhadap pasien dengan jumlah 3053 data pasien *Intensive Care Unit* (ICU) yang berumur 20 tahun keatas. Hasil HSI dari penelitian Dung-Hung *et al.* (2022) mampu memprediksi 72% dari total data pasien yang menerima intervensi hemodinamik dengan spesifisitas sebesar 67%.

Jika dibandingkan dengan penelitian tersebut, penelitian ini menggunakan 3055 data pasien dengan umur 17 tahun keatas yang mendapatkan penanganan premedikasi dengan cara pendekatan model *machine learning neural network feedforward* untuk memprediksi perubahan hemodinamik dari pasien dengan hasil prediksi keseluruhan 85%. Kemudian untuk *precision* dari penelitian ini, mendapatkan hasil 0,85 untuk kelas normal, 0,81 untuk kelas hipertensi, dan 0,6 untuk kelas hipotensi.

5. Kesimpulan

Penelitian ini telah menghasilkan sebuah model *machine learning neural network* dengan arsitektur 10 *nodes* pada *input layer*, 10 *nodes* pada *hidden layer*, dan 3 *nodes* pada *output layer*, yang terbukti mampu memprediksi perubahan hemodinamik pada pasien setelah pemberian premedikasi dengan akurasi sebesar 85%. Model ini juga memiliki *precision* tinggi untuk prediksi kelas normal sebesar 0,85 dan 0,81 untuk prediksi kelas hipertensi dengan *recall* masing-masing yaitu 1 (tinggi) dan 0,6 (sedang). Di sisi lain model masih memiliki keterbatasan dalam memprediksi kelas hipotensi karena kurangnya sampel yang didapat. Secara keseluruhan, hasil penelitian ini telah menunjukkan potensi model dalam meningkatkan pemahaman dan penerapan teknologi guna membantu dalam penanganan medis. Model

yang dikembangkan dapat memprediksi perubahan hemodinamik pasien setelah premedikasi.

Daftar Pustaka

- Letaifa, A.B., 2019. Chapter Four - SSIM and ML Based QoE Enhancement Approach in SDN Context. *Advances in Computers*, 114, 151-196. <https://doi.org/10.1016/bs.adcom.2019.02.004>
- Currie, G., Hawk, K.E., Rohren, E., Vial, A., Klein, R., 2019. Machine Learning and Deep Learning in Medical Imaging: Intelligent Imaging. *Journal of Medical Imaging and Radiation Sciences*, 50(4), 477-487. <https://doi.org/10.1016/j.jmir.2019.09.005>
- Dastres, R., Soori, M., 2021. Artificial Neural Network Systems. *International Journal of Imaging and Robotics (IJIR)*, 21(2), 13-25.
- Dung-Hung, C., Cong, T., Zeyu, J., Yu-Shan, O.-Y., Yung-Yan, L., 2022. External Validation of a Machine Learning Model to Predict Hemodynamic Instability in Intensive Care Unit. *Critical Care*, 26(215), 1-10. <https://doi.org/10.1186/s13054-022-04088-9>
- El Bouchefry, K., de Souza, R.S., 2020. Chapter 12 - Learning in Big Data: Introduction to Machine Learning. *Knowledge Discovery in Big Data from Astronomy and Earth Observation*, 225-249. <https://doi.org/10.1016/B978-0-12-819154-5.00023-0>
- Janiesch, C., Zschech, P., Heinrich, K., 2021. Machine Learning and Deep Learning. *Electronic Markets*, 31, 685-695. <https://doi.org/10.1007/s12525-021-00475-2>
- Jeong, Y.-S., Kang, A.R., Jung, W., Lee, S.J., Lee, S., Lee, M., Chung, Y.H., Koo, B.S., Kim, S.H., 2019. Prediction of Blood Pressure after Induction of Anesthesia Using Deep Learning: A Feasibility Study. *Applied Sciences*, 9(23), 5135. <https://doi.org/10.3390/app9235135>
- Koshire, A., Kandikatla, P.S., Pawar, H., 2022. Comparison of Haemodynamic Response among Patients Posted for Laparoscopic Cholecystectomy with or without Oral Clonidine as Premedication-A Prospective Comparative Study. *MVP Journal of Medical Sciences*, 8(1), 54-59.
- Simonneau, G., Montani, D., Celermajer, D.S., Denton, C.P., Gatzoulis, M.A., Krowka, M., Williams, P.G., Souza, R., 2019. Haemodynamic definitions and updated clinical classification of pulmonary hypertension. *European Respiratory Journal*, 53(1), 1801913. <https://doi.org/10.1183/13993003.01913-2018>
- Urso, A., Fiannaca, A., La Rosa, M., Ravi, V., Rizzo, R., 2019. Data Mining: Prediction Methods. *Encyclopedia of Bioinformatics and Computational Biology*, 1, 413-430. <https://doi.org/10.1016/B978-0-12-809633-8.20462-7>

Xie, Y., Chen, Y., Lian, Q., Yin, H., Peng, J., Sheng, M., Wang, Y., 2022. Enhancing Real-Time Prediction of Effluent Water Quality of Wastewater Treatment Plant Based on Improved Feedforward Neural Network Coupled with Optimization Algorithm. *Water*, 14(7), 1053. <https://doi.org/10.3390/w14071053>

Yakimovich, A., Beaugnon, A., Huang, Y., Ozkirimli, E., 2021. Labels in a Haystack: Approaches Beyond Supervised Learning in Biomedical Applications. *Patterns*, 2(12), 1-11. <https://doi.org/10.1016/j.patter.2021.100383>