

Klasifikasi Status Tekanan Darah memanfaatkan Sinyal Photoplethysmograph berbasis Metode *Random Forest*

UNANG SUNARYA¹, LYRA VEGA UGI²

¹Fakultas Ilmu Terapan, Universitas Telkom, Indonesia

²Fakultas Teknik Elektro, Universitas Telkom, Indonesia

Email: unangsunarya@telkomuniversity.ac.id

Received 27 Februari 2024 | Revised 14 Mei 2024 | Accepted 5 Juni 2024

ABSTRAK

Berbagai teknik pengukuran tekanan darah telah banyak dilakukan salah satunya melalui metode tidak langsung (noninvasive) dengan pemasangan sensor-sensor pada bagian tubuh tertentu, kemudian hasilnya dianalisis dengan algoritma kecerdasan buatan. Namun, masih terdapat banyak kendala pada pemilihan algoritma yang tepat untuk mencapai hasil akurasi klasifikasi yang tinggi. Pada penelitian ini dilakukan klasifikasi status tekanan darah dengan menggunakan sinyal photoplethysmograph (PPG) yang pengukurannya dilakukan secara non-invasive dari 219 pasien. Algoritma random forest digunakan untuk mengklasifikasikan status pasien ke dalam empat kelas yaitu normal, prehypertension, stage 1 prehypertension dan stage 2 prehypertension. Untuk perbandingan, dataset juga diklasifikasikan dengan algoritma KNN dan SVM. Hasil menunjukkan bahwa algoritma random forest memberikan kinerja terbaik dengan akurasi sebesar 98,63%, presisi 98,72% dan recall 98.60%.

Kata kunci: tekanan darah, CVD, random forest, KNN, SVM

ABSTRACT

Various ways for measuring blood pressure have been employed, including non-invasive techniques that include placing sensors on specific body areas and analyzing the finding using artificial intelligence algorithms. Nevertheless, there are numerous challenges in choosing the appropriate algorithms that yielded high accuracy in classification. In this study, blood pressure status was classified using photoplethysmograph (PPG) signals, which were measured non-invasively from 219 patients. The random forest algorithm was used to classify patient status into four classes, namely normal, prehypertension, prehypertension stage 1 and prehypertension stage 2. For comparison, the dataset was also classified using the KNN and SVM algorithms. The results show that the random forest algorithm provides the best performance with an accuracy of 98.63%, precision of 98.72% and recall of 98.60%, respectively.

Keywords: blood pressure, CVD, random forest, KNN, SVM

1. PENDAHULUAN

Tekanan darah tinggi atau hipertensi merupakan salah satu masalah kesehatan global yang serius dan menjadi faktor risiko utama untuk berkembangnya penyakit jantung (**Mills, dkk, 2020**). Menurut *World Health Organization*, hipertensi menjadi penyebab utama kematian di seluruh dunia, menyebabkan jutaan orang mengalami komplikasi kesehatan yang mengancam nyawa setiap tahunnya (**World Health Organization, 2024**). Penyakit jantung, yang melibatkan gangguan struktural atau fungsional jantung, termasuk di antaranya penyakit arteri koroner, gagal jantung, dan penyakit katup jantung (**Drozd & Kawecka-Jaszcz, 2014**). Hipertensi diakui sebagai salah satu faktor risiko utama yang dapat menyebabkan perubahan struktural pada pembuluh darah dan jantung, yang pada akhirnya dapat mengarah pada pengembangan penyakit kardiovaskular (**Mrowka, 2020**)(**Saheera & Krishnamurthy, 2020**). Oleh karena itu, pemahaman mendalam tentang tekanan darah tinggi dapat membuka pintu menuju strategi intervensi yang lebih terarah untuk deteksi dini penyakit jantung. Dalam praktiknya pengukuran tekanan darah dapat dilakukan secara *invasive* atau *noninvasive* (**Kaur, dkk, 2019**). Pengukuran secara *invasive* dilakukan secara langsung dengan memasukkan alat ke dalam tubuh yang memiliki dampak dapat menyakiti pasien hingga berakibat luka (**Bibbo, dkk, 2020**). Selain itu pengukuran secara *invasive* hanya dilakukan di rumah sakit oleh praktisi di bidangnya yang dalam hal ini akan membuat biaya yang tinggi dan tidak fleksibel karena harus selalu pergi ke rumah sakit. Pilihan lainnya adalah dengan metode *noninvasive* yaitu pengukuran secara tidak langsung dengan penggunaan sensor yang dipasang secara portabel pada tubuh (**Fortin, dkk, 2021**). kemudian hasil pembacaan dapat dianalisis dengan menggunakan bantuan kecerdasan buatan. Penggunaan metode *noninvasive* dianggap lebih fleksibel namun pemilihan algoritma kecerdasan buatan yang kurang tepat dapat mengakibatkan akurasi hasil pengukuran tekanan darah menjadi tidak akurat. Oleh karena itu, analisis penggunaan algoritma kecerdasan buatan sangat penting pada metode *noninvasive*. Dengan demikian, penelitian klasifikasi tekanan darah dengan penggunaan kecerdasan buatan pada metode *noninvasive* ini sangat penting dilakukan, selain dapat mempermudah pengukuran tekanan darah pada pasien juga memberikan hasil klasifikasi yang akurat dan relatif lebih cepat dibandingkan metode konvensional *invasive*.

Berbagai metode *artificial intelligence* (AI) untuk deteksi tekanan darah telah banyak dilakukan baik menggunakan metode *machine learning* ataupun *deep learning* (DL). Metode *linear regression* dengan sinyal *photoplethysmogram* (PPG) telah digunakan untuk mengestimasi tekanan darah tinggi (**Wang, dkk, 2014**). Estimasi tekanan darah tinggi dapat juga dilakukan menggunakan metode *artificial neural network* (ANN) dengan mengombinasikan sinyal *electrocardiogram* (ECG) dan PPG (**Senturk, dkk, 2018**). Selain menggunakan metode *machine learning* (ML) konvensional, metode DL dengan algoritma long short-term memory telah digunakan untuk estimasi tekanan darah dengan mengombinasikan sinyal balliscardiogram (BCG), ECG, dan PPG (**Lee, dkk, 2021**). Deteksi tekanan darah juga dapat dilakukan secara nonlinear menggunakan metode *support vector machine* (SVM) pada sinyal ECG kanal tunggal (**Eshaghi, dkk, 2020**)(**Panagoulis, dkk, 2022**). Selain menggunakan metode ML dan DL, metode transfer learning (TL) banyak digunakan untuk estimasi tekanan darah tinggi dengan cara memanfaatkan kembali model yang telah dilatih sebelumnya selanjutnya diterapkan untuk properti tekanan darah lainnya, dengan memanfaatkan model yang pernah dilatih sebelumnya maka akan mempercepat dalam pelatihan kembali untuk data atau properti baru yang diekstrak dari data tekanan darah (**Wang, dkk, 2022**)(**Shaikh, dkk, 2023**). Dalam praktiknya, pengukuran tekanan darah dapat dilakukan secara *invasive* dan *noninvasive* (**P., 1970**). Metode *invasive*, yang merupakan standar utama, mengukur tekanan darah secara langsung dengan memasukkan canula ke dalam arteri (**Hendrayana & Agus Riyadi, 2016**)(**Chung, dkk, 2013**). Namun, kelemahan dari pengukuran tekanan darah

dengan cara langsung ini menimbulkan efek yang kurang nyaman bagi pasien yang dapat menimbulkan nyeri dan biasanya dilakukan pada pasien rapat inap di rumah sakit (**Kaur, dkk, 2019**). Alternatif lainnya adalah secara *noninvasive*, yaitu pengukuran tekanan darah secara tidak langsung salah satunya melalui sinyal PPG (**Dal Pont & Marques, 2020**).

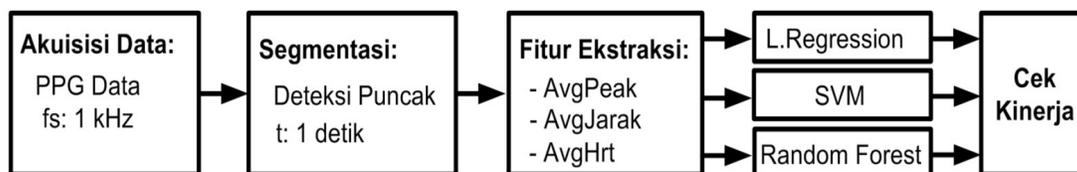
Dalam penelitian ini, status tekanan darah dari sinyal PPG diklasifikasikan menggunakan ML random forest ke dalam empat kelas yaitu normal, prehypertension, stage 1 hypertension, dan stage 2 hypertension. Untuk validasi unjuk kerja algoritma yang digunakan, selanjutnya dilakukan benchmark dengan algoritma linear regression dan *support vector machine* yang merupakan metode banyak digunakan dalam monitoring tekanan darah. Ada lima fitur yang diekstrak dari sinyal PPG ini, di antaranya adalah puncak rata-rata dari setiap segmen sinyal PPG (*avgpeak*), jarak rata-rata anatar puncak sinyal PPG (*avgjarak*), heart rate rata-rata dari tiap segmen sinyal PPG (*avgheart*), *diastolic*, dan *systolic* tekanan darah.

Selanjutnya pada bab 2 dibahas dataset dan metode yang digunakan dalam penelitian ini, mulai dari segmentasi, pemrosesan awal sinyal PPG, fitur ekstraksi dan metode klasifikasi yang digunakan. Hasil *benchmark* dari ketiga metode dibahas pada bab 4, selanjutnya disimpulkan pada bab 4.

2. METODOLOGI PENELITIAN

2.1 Diagram Blok Metode Klasifikasi Status Tekanan Darah

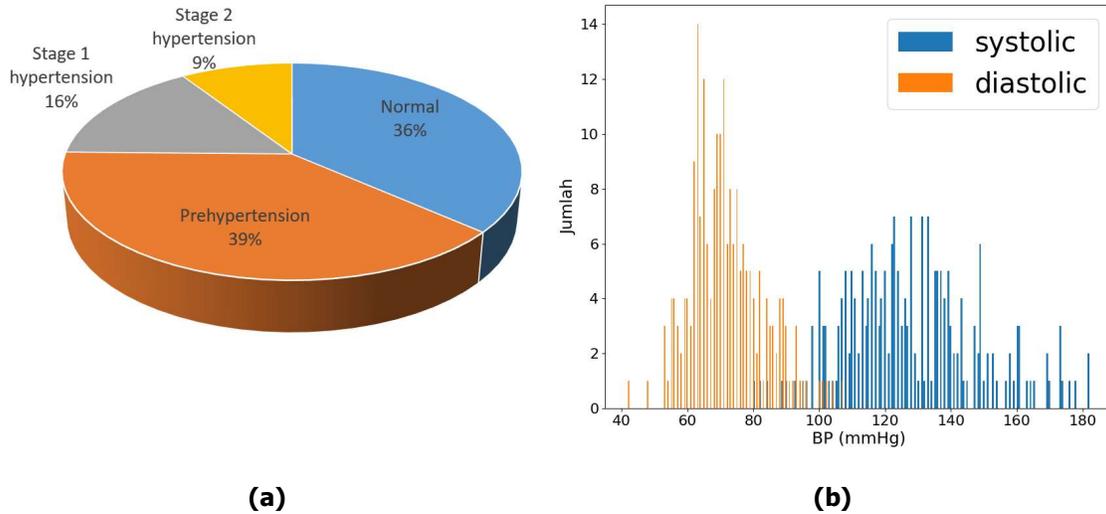
Gambar 1 menunjukkan diagram blok keseluruhan untuk klasifikasi status tekanan darah. Sistem dimulai dengan akuisisi data subjek yang berupa sinyal PPG yang kemudian disegmentasi untuk mendapatkan titik puncak dari masing-masing sinyal PPG. Selanjutnya dilakukan ekstraksi ciri dari setiap sinyal PPG yang telah disegmentasi dan diketahui titik puncaknya. Fitur-fitur yang telah diekstraksi tersebut kemudian digunakan untuk melatih model yang dan diklasifikasi oleh metode klasifikasi. Untuk perbandingan digunakan tiga buah pengklasifikasi yang terdiri dari metode linear legression, *support vector machine*, dan random forest.



Gambar 1. Diagram Blok Sistem Keseluruhan Klasifikasi Status Tekanan Darah

2.2 Dataset

Adapun dataset yang digunakan pada penelitian ini adalah dataset PPG yang merupakan *public dataset* yang dapat diunduh pada alamat https://figshare.com/articles/dataset/PPG-BP_Database_zip.



Gambar 2. Informasi Proporsi Dataset: (a) Empat Kelas Status Tekanan Darah Tinggi dan (b) Sebaran *Diastolic* dan *Systolic* Tekanan Darah Pada 219 Subyek Observasi

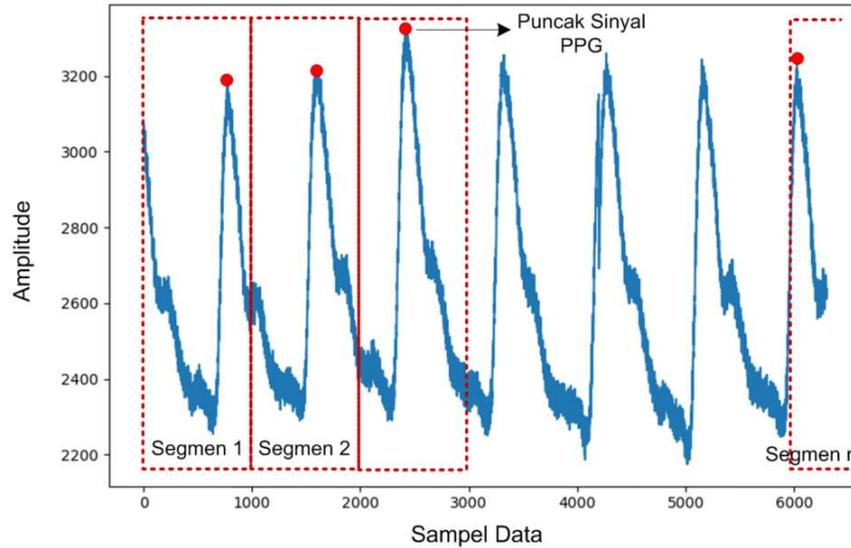
Terdapat 219 subyek yang terlibat dalam pengambilan sampel data PPG ini dengan rentang usia antara 20 s.d. 89 tahun. Pengambilan data PPG dilakukan secara *noninvasive* pada pasien yang sehat dan memiliki tekanan darah tinggi pada frekuensi sampling 1 kHz. Gambar 2(a) menunjukkan empat kelas status tekanan darah tinggi dari dataset sinyal PPG dengan porsi normal 36%, prehypertension 39%, stage 1 hypertension 16%, dan stage 2 hypertension 9% dari seluruh subyek penelitian. Gambar 2(b) informasi keseluruhan tekanan darah *diastolic* dan *systolic* dari seluruh subyek observasi (Liang, dkk, 2018).

2.3 Segmentasi

Sebelum dilakukan ekstraksi fitur dari sinyal PPG, terlebih dahulu dilakukan proses segmentasi sinyal. Gambar 3 menunjukkan proses segmentasi pada sinyal PPG. Proses segmentasi ini dilakukan untuk mempermudah mendapatkan titik puncak gelombang pada sinyal PPG (Yang, dkk, 2020). Sinyal PPG disegmentasi sebesar 1 detik pada frekuensi 1 kHz, sehingga didapatkan sampel data sebanyak 1000 menggunakan Persamaan (1) sebagai berikut:

$$Sample = f_s \times t_s \quad (1)$$

di mana f_s adalah frekuensi sampling dari sinyal PPG dan t_s adalah waktu yang digunakan untuk sampling sinyal.



Gambar 3. Penentuan Titik Puncak PPG dengan Proses Segmentasi

2.4 Amplitudo Rata-rata

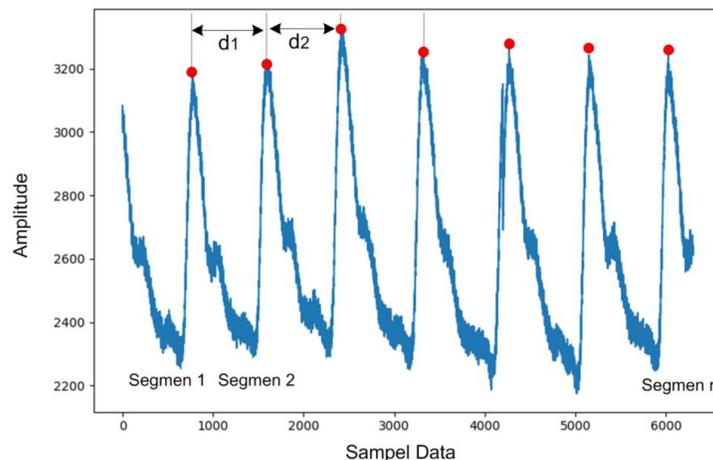
Amplitudo rata-rata merupakan fitur pertama yang diekstrak dari sinyal PPG yang telah disegmentasi. Amplitudo juga menunjukkan puncak dari satu segmen sinyal PPG. Untuk setiap subyek dengan panjang sampel data 6000 terdiri dari enam titik amplitudo. Sehingga amplitudo rata-rata dapat dihitung menggunakan Persamaan (2) sebagai berikut:

$$AvgPeak = \frac{1}{N} \sum_{i=1}^N A_i \quad (2)$$

di mana $AvgPeak$ menunjukkan amplitudo rata-rata gelombang PPG, N adalah banyaknya puncak, dan A adalah amplitudo puncak setiap segmen data PPG.

2.5 Jarak Puncak ke Puncak Rata-rata

Adapun fitur kedua yang diekstrak dari sinyal PPG adalah jarak dari puncak ke puncak dari dua segmen sinyal PPG yang berdekatan seperti terlihat pada Gambar 4.



Gambar 4. Jarak Puncak ke Puncak Dua Segmen Sinyal PPG yang Berdekatan

Untuk menghitung jarak rata-rata antara dua puncak sinyal PPG yang berdekatan, dapat menggunakan Persamaan (3) sebagai berikut:

$$AvgJarak = \frac{1}{N-1} \sum_{i=1}^{N-1} (d_{i+1} - d_i) \quad (3)$$

di mana $AvgJarak$ adalah jarak rata-rata dari semua puncak sinyal PPG pada satu subyek, N adalah jumlah puncak gelombang, dan d adalah jarak antar dua puncak gelombang yang saling berdekatan.

2.6 Heart Rate

Heart rate merupakan salah satu fitur yang dapat digunakan untuk prediksi penyakit cardiovascular atau semua penyebab kematian secara umum (**Tadic, dkk, 2018**). Selain itu heart rate juga merupakan indikator klinis dan nilai prognosis risiko kardiovaskular pada penderita penyakit tekanan darah tinggi (**Kishi, 2020**). Rata-rata heart rate dalam satu menit dapat dihitung dengan menggunakan Persamaan (4) sebagai berikut:

$$AvgHrt = \frac{1}{N} \sum_{i=1}^N \left(\frac{f_s}{d_i} \right) \times 60 \quad (4)$$

di mana N adalah jumlah jarak puncak ke puncak dari sinyal PPG, f_s adalah frekuensi sampling dari sinyal PPG, dan d adalah jarak antara dua puncak sinyal PPG yang berdekatan.

2.7 Random Forest

Random Forest (RF) adalah salah satu algoritma klasifikasi dan regresi yang paling banyak digunakan dalam pembelajaran mesin. Algoritma RF terdiri dari kumpulan algoritma pohon keputusan, atau pohon keputusan, yang memperbaiki kelemahan yang ada pada pohon keputusan. Untuk menghindari *overfitting* karena model yang kompleks, RF menggunakan metode *bagging* dalam implementasinya (**Raschka & Mirjalili, 2017**).

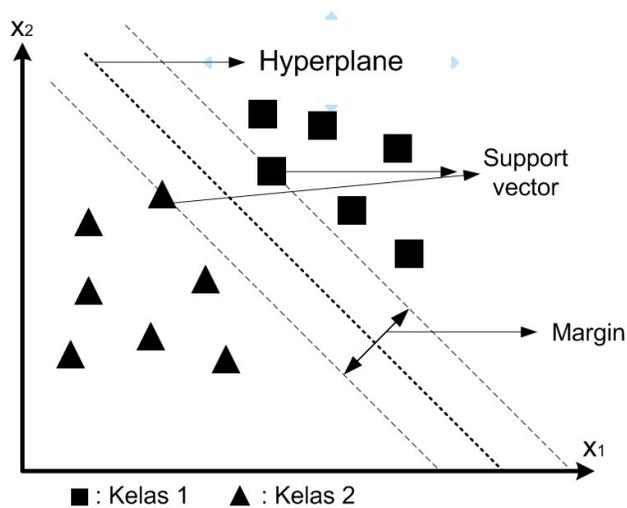
2.8 Support vector Machine

Support vector machine merupakan salah satu algoritma pembelajaran mesin yang banyak digunakan untuk menyelesaikan kasus klasifikasi atau regresi. Algoritma ini bekerja dengan mencari *hyperplane* yang memperbesar jarak diantara kelas-kelas yang berbeda. Gambar 5 menunjukkan *hyperplane* yang memisahkan jarak antara *support vector* yang mewali sampel data secara linear (**Raschka & Mirjalili, 2017**). Pada beberapa kasus nonlinear, penggunaan kernel banyak dilakukan untuk meningkatkan kinerja akurasi klasifikasi (**Begg, dkk, 2005**), salah satunya adalah kernel *radial basis function* (RBF) yang dirumuskan pada Persamaan (5) di bawah ini:

$$k(a^{(i)}, a^{(j)}) = \exp\left(-\gamma \|a^{(i)}, a^{(j)}\|^2\right) \quad (5)$$

di mana a adalah sampel data, $\|a^{(i)}, a^{(j)}\|^2$ adalah jarak Euclidean antara dua titik sampel data $a^{(i)}$ dan $a^{(j)}$, sedangkan γ adalah hyperparameter yang dioptimasi dirumuskan dengan $\gamma = \frac{1}{2\sigma^2}$

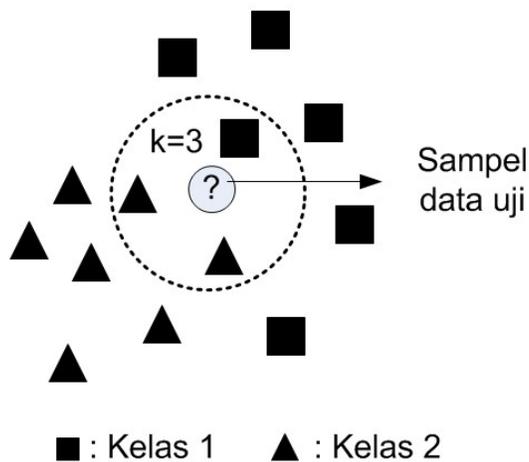
yang mengindikasikan fungsi similarity diantara sepasang sampel data (**Raschka & Mirjalili, 2017**).



Gambar 5. Ilustrasi *Hyperplane* Pada *Support vector* Machine Linear

2.9 K-Nearest Neighbors

K-nearest neighbors adalah salah satu algoritma kecerdasan buatan tanpa parameter atau lebih dikenal dengan istilah *instance-based learning algorithm* (**Raschka & Mirjalili, 2017**). Adapun cara kerja dari algoritma ini adalah dengan memilih sejumlah k tetangga terdekat yang dihitung dengan algoritma jarak terdekat terhadap sampel data uji yang akan diklasifikasi. Selanjutnya dilakukan voting untuk menghitung seberapa banyak kelas yang terdekat ke sampel uji dari k tetangga terdekat. Jumlah kelas label terbanyak akan menjadi keputusan sampel data tersebut diklasifikasikan seperti terlihat pada Gambar 6.



Gambar 6. Proses Klasifikasi KNN dengan Tiga Tetangga Terdekat ($k = 3$)

2.10 Metrik Evaluasi

Untuk validasi kinerja sistem, algoritma pembelajaran mesin dievaluasi menggunakan tiga metrik utama yang meliputi akurasi klasifikasi, *recall*, dan presisi.

Adapun untuk perhitungan kinerja akurasi klasifikasi algoritma dapat diformulasikan dengan menggunakan Persamaan (6) sebagai berikut:

$$Akurasi = \frac{TP+TN}{TP+TN+FN+FP} \quad (6)$$

di mana TP adalah nilai true positive, TN true negative, FN false negative, dan FP adalah false positive.

Recall mendeskripsikan seberapa banyak hasil prediksi yang benar terhadap jumlah nilai aktual data (**Olson & Delen, 2008**). Untuk menghitung nilai *Recall* dapat digunakan Persamaan (7).

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

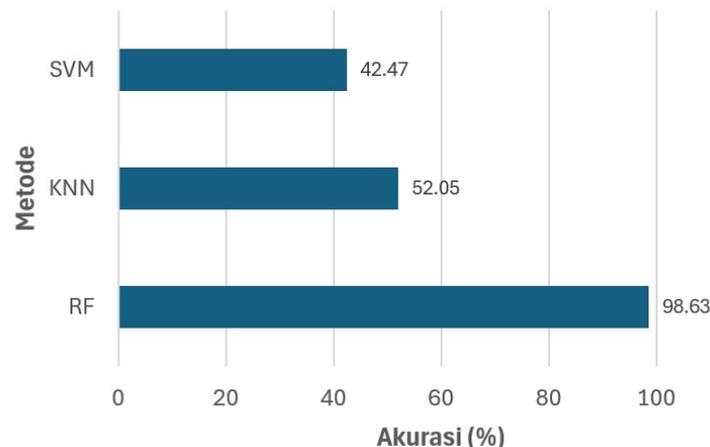
Sedangkan Presisi menunjukkan seberapa banyak hasil data aktual yang benar terhadap keseluruhan hasil prediksi yang benar (**Olson & Delen, 2008**). Adapun nilai Presisi dapat dihitung dengan menggunakan Persamaan (8) sebagai berikut:

$$Presisi = \frac{TP}{TP+FP} \quad (8)$$

3. HASIL DAN PEMBAHASAN

3.1 Perbandingan Kinerja Akurasi Tekanan Darah

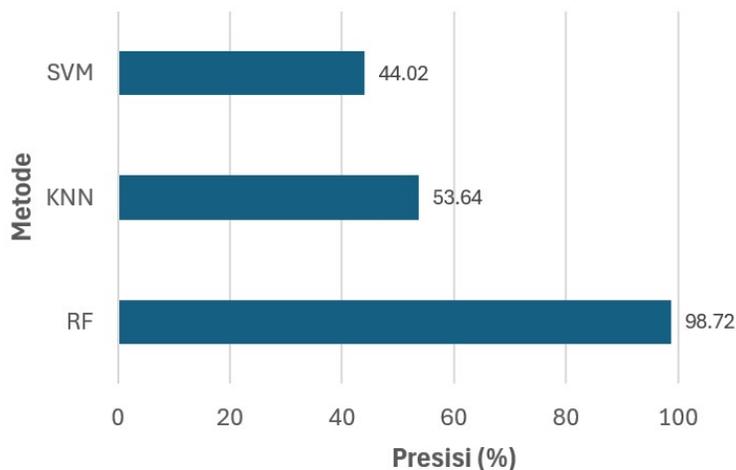
Gambar 7 membandingkan hasil akurasi klasifikasi dari metode SVM, KNN, dan RF. Hasil menunjukkan bahwa metode RF mencapai nilai akurasi tertinggi dengan angka sebesar 98,63 %. Sedangkan KNN menempati urutan kedua dengan nilai akurasi sebesar 52,05 % disusul dengan algoritma SVM dengan nilai akurasi sebesar 42,47%. Terdapat deviasi sebesar 46,58 % antara RF dan KNN. Hal ini menunjukkan bahwa metode RF superior dalam melakukan prediksi untuk data yang diklasifikasi ke dalam empat kelas status tekanan darah yang berbeda.



Gambar 7. Kinerja Akurasi Klasifikasi Status Tekanan Darah dari Tiga Algoritma: RF, KNN, Dan SVM

3.2 Perbandingan Kinerja Presisi Tekanan Darah

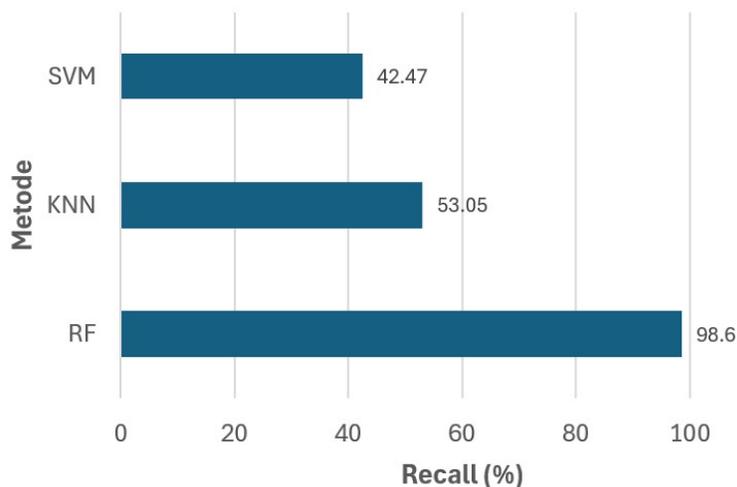
Selain kinerja akurasi, dalam penelitian ini juga diukur kinerja presisi dari metode-metode yang digunakan. Gambar 8 menunjukkan perbandingan kinerja akurasi dari metode SVM, KNN, dan RF. Hasil menunjukkan bahwa kinerja presisi pada metode RF (98,72%) mengungguli kedua metode lainnya yaitu SVM (44,02%) dan KNN (53,64%). Jika dibandingkan dengan metode SVM, RF memiliki kinerja presisi lebih dari dua kali lipat (2,24 kali) metode SVM.



Gambar 8. Kinerja Presisi Status Tekanan Darah dari Tiga Algoritma: RF, KNN, dan SVM

3.3 Perbandingan Kinerja Recall Tekanan Darah

Gambar 9 menunjukkan perbandingan kinerja *recall* dari metode RF, KNN, dan SVM. Hasil menunjukkan bahwa metode RF memiliki kinerja *recall* yang relatif lebih tinggi dibandingkan dengan metode SVM ataupun KNN. Kinerja *recall* pada metode RF (98,6%) lebih unggul sebesar 45,55% dibandingkan metode KNN (53,03%) dan lebih besar 56,13 % dari metode SVM (42,47%).



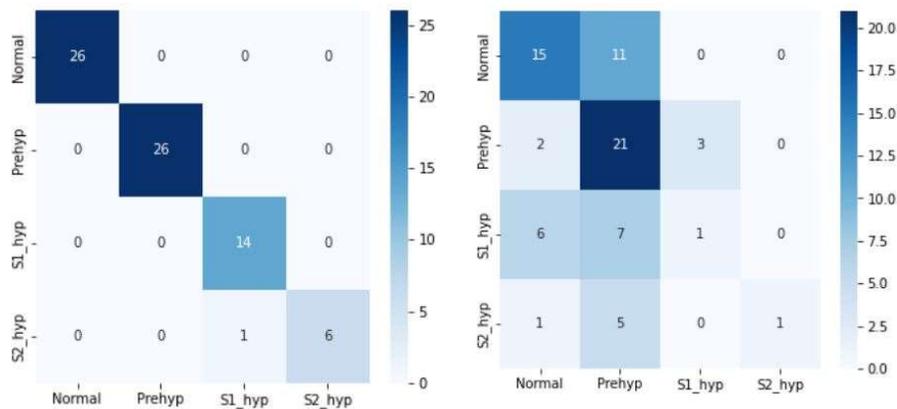
Gambar 9. Kinerja Recall/Status Tekanan Darah dari Tiga Algoritma: RF, KNN, dan SVM

Berdasarkan kinerja akurasi, presisi, dan *recall* dari ketiga metode, metode RF menunjukkan hasil yang superior jika dibandingkan dengan metode KNN dan SVM baik dalam hal kinerja akurasi, presisi ataupun *recall*.

3.4 Perbandingan *Heatmap* Hasil Prediksi Tekanan Darah

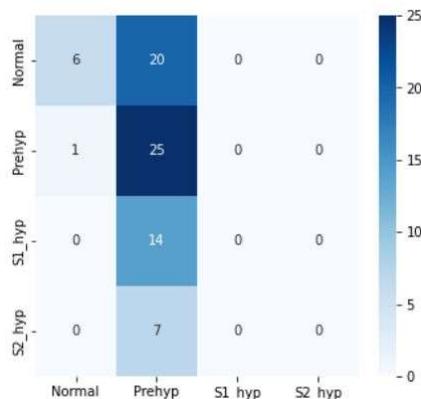
Untuk validasi hasil kinerja akurasi, presisi, dan *recall*, pada penelitian ini juga disajikan *heatmap* dari ketiga metode (RF, KNN, dan SVM) untuk melihat sebaran hasil prediksi metode dari data yang diuji terhadap kelasnya. Gambar 10 menunjukkan perbandingan *heatmap* dari metode RF, KNN, dan SVM. Adapun nilai yang muncul dalam matrik secara diagonal dari atas kiri ke kanan bawah menunjukkan jumlah data yang diprediksi benar terkait kelasnya. Dalam hal ini terdiri dari tiga kelas (status) yaitu *normal*, *prehypertension*, *stage 1 prehypertension* dan *stage 2 prehypertension*. Artinya semakin besar nilai yang ada pada arah diagonal tersebut menunjukkan semakin besar data yang diprediksi benar oleh metode yang digunakan.

Gambar 10(a) merupakan *heatmap* pada metode RF yang menunjukkan hasil prediksi yang lebih baik jika dibandingkan dengan kedua metode lainnya yaitu KNN dan SVM. Pada metode RF hampir semua data uji dapat diprediksi sesuai kelasnya masing-masing dengan sangat baik kecuali satu buah data pada kelas *stage 2 prehypertension*. Sedangkan pada kelas lainnya dapat diprediksi dengan benar sebesar 100%. Berbeda dengan metode KNN pada Gambar 10(b), sebagian besar data hanya dapat diprediksi benar hanya pada kelas *normal* dan *prehypertension*. Sedangkan untuk kelas lainnya sangat kecil sekali hanya sebesar 7,14% pada kelas *stage 1 prehypertension* dan 14,28% pada kelas *stage 2 prehypertension*. Sedangkan untuk metode SVM, sebagian besar data diprediksi benar hanya pada kelas *prehypertension*, sedangkan pada kelas lainnya sangat kecil sekali seperti pada kelas *stage 1 prehypertension* dan *stage 2 prehypertension* tingkat keberhasilan prediksinya sebesar 0% sedangkan pada kelas *normal* sebesar 23,07%.



(a) RF

(b) KNN



(c) SVM

Gambar 10. Heatmap Seberapa Signifikan Kesesuaian Antara Sampel yang Diprediksi Benar Terhadap Label Kelasnya dari Ketiga Method : (A) RF, (B) KNN, dan (C) SVM

Selain melakukan validasi dengan mengevaluasi *heatmap* dari masing-masing metode, dalam penelitian ini juga dilakukan validasi keandalan metode dengan penggunaan algoritma optimasi *random search* (Sunarya & Haryanti, 2022). Di mana algoritma optimasi *random search* bekerja dengan mencari hyperparameter yang paling signifikan dari setiap metode yang digunakan untuk mendapatkan hasil kinerja yang terbaik. Tabel 1 menunjukkan perbandingan hasil kinerja algoritma sebelum optimasi (MTO) dan setelah optimasi (MDO) untuk setiap metrik evaluasi akurasi, presisi, dan *recall* pada masing-masing algoritma RF, KNN, dan SVM.

Tabel 1. Validasi Metode yang Digunakan dengan Penambahan Algoritma Optimasi *Random search*

Metode	Akurasi (%)		Presisi (%)		Recall (%)	
	MTO	MDO	MTO	MDO	MTO	MDO
RF	98,63	100	98,72	100	98,60	100
KNN	52,05	57,14	53,64	85,71	53,05	57,14
SVM	42,47	90,47	44,02	92,85	42,47	90,48
<i>MTO: Metode Tanpa Optimasi</i>						
<i>MDO: Metode Dengan Optimasi</i>						

Hasil menunjukkan bahwa, ada kenaikan kinerja dari setiap metode setelah dilakukan proses optimasi menggunakan *random search*. Kinerja paling dominan ditunjukkan pada algoritma RF di mana untuk setiap metrik evaluasinya mencapai 100 % untuk akurasi, presisi, dan *recall*. Pada metode KNN, kenaikan signifikan dicapai pada metrik evaluasi presisi, meningkat sebesar 32,07%, dari 53,64% menjadi 85,71%. Sedangkan untuk metode SVM terdapat peningkatan kinerja di semua metrik evaluasi sebesar 48% untuk akurasi, 48,83% presisi dan 48,01% untuk *recall*.

4. KESIMPULAN

Berdasarkan hasil pengujian kinerja dari ketiga metode yaitu RF, KNN, dan SVM dalam mengklasifikasikan status tekanan darah ke dalam empat kelas yaitu *normal*, *prehypertension*,

stage 1 prehypertension, dan stage 2 prehypertension, menunjukkan bahwa metode RF memberikan kinerja yang unggul baik dilihat dari hasil kinerja akurasi (98,63%), presisi (98,72%) maupun recall (98,6%). Sehingga dapat disimpulkan bahwa metode RF dapat mengelompokkan status tekanan darah subjek dengan sangat baik dari sinyal PPG.

DAFTAR RUJUKAN

- Begg, R. K., Palaniswami, M., & Owen, B. (2005). *Support vector Machines for Automated Gait Classification. IEEE Transactions on Biomedical Engineering, 52*(5), 828–838. <https://doi.org/10.1109/TBME.2005.845241>
- Bibbo, D., Kijonka, J., Kudrna, P., Penhaker, M., Vavra, P., & Zonca, P. (2020). Design and development of a novel *invasive* blood pressure simulator for patient's monitor testing. *Sensors (Switzerland), 20*(1). <https://doi.org/10.3390/s20010259>
- Chung, E., Chen, G., Alexander, B., & Cannesson, M. (2013). Non-*invasive* continuous blood pressure monitoring: A review of current applications. *Frontiers of Medicine in China, 7*(1), 91–101. Higher Education Press Limited Company. <https://doi.org/10.1007/s11684-013-0239-5>
- Dal Pont, M. P., & Marques, J. L. B. (2020). Reflective Photoplethysmography Acquisition Platform With Monitoring Modules and *Noninvasive* Blood Pressure Calculation. *IEEE Transactions on Instrumentation and Measurement, 69*(8), 5649–5657. <https://doi.org/10.1109/TIM.2019.2963508>
- Drozd, D., & Kawecka-Jaszcz, K. (2014). Cardiovascular changes during chronic hypertensive states. *Pediatric nephrology (Berlin, Germany), 29*(9), 1507–1516. <https://doi.org/10.1007/s00467-013-2614-5>
- Eshaghi, F., Aghdam, E. N., & Kassiri, H. (2020). A Resource-Optimized Patient-Specific Nonlinear-SVM Hypertension Detection Algorithm for Minimally-*Invasive* High Blood Pressure Control. *2020 IEEE International Symposium on Circuits and Systems (ISCAS)*, (pp. 1–5). <https://doi.org/10.1109/ISCAS45731.2020.9180433>
- Fortin, J., Rogge, D. E., Fellner, C., Flotzinger, D., Grond, J., Lerche, K., & Saugel, B. (2021). A novel art of continuous *noninvasive* blood pressure measurement. *Nature Communications, 12*(1). <https://doi.org/10.1038/s41467-021-21271-8>
- Hendrayana, Y. H., & Agus Riyadi, M. (2016). *Rancang Bangun Alat Pengukur Tekanan Darah Otomatis Menggunakan Metode Oscillometry Berbasis Raspberry Pi Model B+*. Transmisi 18(1)

- Kaur, B., Kaur, S., Yaddanapudi, L. N., & Singh, N. V. (2019). Comparison between *invasive* and *noninvasive* blood pressure measurements in critically ill patients receiving inotropes. *Blood Pressure Monitoring, 24*(1), 24–29. <https://doi.org/10.1097/MBP.0000000000000358>
- Kishi, T. (2020). Heart rate Is the Clinical Indicator of Sympathetic Activation and Prognostic Value of Cardiovascular Risks in Patients With Hypertension. *Hypertension, 76*(2), 323–324. <https://doi.org/10.1161/HYPERTENSIONAHA.120.14898>
- Lee, D., Kwon, H., Son, D., Eom, H., Park, C., Lim, Y., Seo, C., & Park, K. (2021). Beat-to-beat continuous blood pressure estimation using bidirectional long short-term memory network. *Sensors (Switzerland), 21*(1), 1–15. MDPI AG. <https://doi.org/10.3390/s21010096>
- Liang, Y., Chen, Z., Liu, G., & Elgendi, M. (2018). A new, short-recorded photoplethysmogram dataset for blood pressure monitoring in China. *Scientific Data, 5*. <https://doi.org/10.1038/sdata.2018.20>
- Mills, K. T., Stefanescu, A., & He, J. (2020). The global epidemiology of hypertension. *Nature Reviews Nephrology, 16*(4), 223–237. <https://doi.org/10.1038/s41581-019-0244-2>
- Mrowka, R. (2020). Recent advances in blood pressure research. *Acta Physiologica, 228*(1). Blackwell Publishing Ltd. <https://doi.org/10.1111/apha.13412>
- Olson, D. L., & Delen, Dursun. (2008). *Advanced data mining techniques*. Springer.
- P., P. J. (1970). The Direct and Indirect Measurement of Blood Pressure. *Journal of The Royal Naval Medical Service, 56*(3), 289.6-290. <https://doi.org/10.1136/jrnms-56-289e>
- Panagoulas, D. P., Sotiropoulos, D. N., & Tsihrintzis, G. A. (2022). SVM-Based Blood Exam Classification for Predicting Defining Factors in Metabolic Syndrome Diagnosis. *Electronics (Switzerland), 11*(6). <https://doi.org/10.3390/electronics11060857>
- Raschka, Sebastian., & Mirjalili, Vahid. (2017). *Python machine learning: machine learning and deep learning with Python, scikit-learn, and TensorFlow*. Packt Publishing.
- Saheera, S., & Krishnamurthy, P. (2020). Cardiovascular Changes Associated with Hypertensive Heart Disease and Aging. *Cell Transplantation, 29*. SAGE Publications Ltd. <https://doi.org/10.1177/0963689720920830>
- Senturk, U., Yucedag, I., & Polat, K. (2018). Cuff-less continuous blood pressure estimation from Electrocardiogram(ECG) and Photoplethysmography (PPG) signals with artificial neural network. *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 1–4. <https://doi.org/10.1109/SIU.2018.8404255>

- Shaikh, M. R., Rao, M., & Subramaniam, G. (2023). A Novel Thermal Imaging Based Transfer-Learning Model To Estimate Blood Pressure. *2023 IEEE 20th International Symposium on Biomedical Imaging (ISBI), 2023-April*, (pp. 1–5). <https://doi.org/10.1109/ISBI53787.2023.10230787>
- Sunarya, U., & Haryanti, T. (2022). Perbandingan Kinerja Algoritma Optimasi pada Metode Random Forest untuk Deteksi Kegagalan Jantung. *Jurnal Rekayasa Elektrika, 18*(4). <https://doi.org/10.17529/jre.v18i4.26981>
- Tadic, M., Cuspidi, C., & Grassi, G. (2018). Heart rate as a predictor of cardiovascular risk. *European Journal of Clinical Investigation, 48*(3). <https://doi.org/10.1111/eci.12892>
- Wang, R., Jia, W., Mao, Z. H., Sciabassi, R. J., & Sun, M. (2014). Cuff-free blood pressure estimation using pulse transit time and heart rate. *International Conference on Signal Processing Proceedings, ICSP, 2015-January*(October), (pp. 115–118). <https://doi.org/10.1109/ICOSP.2014.7014980>
- Wang, W., Mohseni, P., Kilgore, K. L., & Najafizadeh, L. (2022). Cuff-Less Blood Pressure Estimation From Photoplethysmography via Visibility Graph and Transfer Learning. *IEEE Journal of Biomedical and Health Informatics, 26*(5), 2075–2085. <https://doi.org/10.1109/JBHI.2021.3128383>
- World Health Organization. (2024, January 30). *Blood Pressure*. Retrived from www.who.int
- Yang, G., Dai, J., Liu, X., Chen, M., & Wu, X. (2020). Spectral feature extraction based on continuous wavelet transform and image segmentation for peak detection. *Analytical Methods, 12*(2), 169–178. <https://doi.org/10.1039/C9AY02052G>