

BAB II

DASAR TEORI

2.1 KAJIAN PUSTAKA

Peneliti dilakukan oleh Ernia Susana yang meneliti tentang Pengukuran Tekanan Darah *Non-Invasive* Tanpa Manset Menggunakan Metode *Pulse Transit Time* Berbasis *Machine Learning* Multivariat Regresi. Tujuan dari penelitian ini adalah untuk mengukur tekanan darah secara *non-invasif* tanpa manset menggunakan metode *Pulse Transit Time* (PTT) berbasis *machine learning*. pengukuran tekanan darah melalui metode PTT diperoleh dari perhitungan jarak gelombang R-EKG dengan sinyal puncak PPG (*photoplethysmogram*). Masalah utama metode PTT pada beberapa penelitian sebelumnya adalah rendahnya tingkat akurasi yang diestimasi dari nilai sistolik (SBP) dan diastolik (DBP). Metode pengukuran tekanan darah dalam penelitian ini menggunakan perhitungan PTT berbasis regresi multivariat *machine learning*. Hasil yang diharapkan adalah mendapatkan perkiraan nilai tekanan darah sistolik (SBP) dan diastolik (DBP) yang lebih akurat. Penelitian ini merupakan penelitian eksperimental laboratorium pada sukarelawan sehat berusia 20 ± 1 tahun. Pengukuran nilai tekanan darah menggunakan metode PTT pada osilometrik adalah 5 ± 5 mmHg. Nilai tekanan darah yang dihasilkan dengan metode PTT memiliki nilai p untuk estimasi SBP dan DBP masing-masing yaitu 0,7374 dan 0,0262 [3].

Peneliti dilakukan oleh Leli Maharani yang meneliti tentang Implementasi dan Pengukuran Klasifikasi Tekanan Darah Berdasarkan *Pulse Transit Time* Menggunakan Metode Transformasi *Wavelet* dan *Support Vector Machine*. Penelitian ini bertujuan sebagai alternatif cara pengukuran tekanan darah tanpa manset (*cuff*) dengan menggunakan prinsip pengukuran darah langsung. Pengukuran tekanan darah didasarkan pada sinyal Elektrokardiogram (EKG) yang berasal dari jantung dan *Photoplethysmography* (PPG) yang berasal dari detak jantung pada jari. Salah satu metode dasar yang dapat digunakan untuk mengukur tekanan darah secara langsung adalah dengan menggunakan *Pulse Transit Time* (PTT). Dengan hal tersebut peneliti ingin mengimplementasikan suatu metode pengukuran darah berbasis PTT yang diperoleh dari interval waktu sinyal EKG dan

PPG sebelumnya melalui preprocessing menggunakan *transformasi wavelet* untuk mendapatkan data sinyal yang efektif dan efisien. Setelah mendapatkan nilai PTT, selanjutnya diolah menggunakan *Support Vector Machines (SVM)* untuk mengetahui apakah seseorang memiliki tekanan darah normal, prehipertensi, hipertensi stadium 1, atau hipertensi stadium 2 [4].

Peneliti dilakukan oleh Jiaze Wu, Hao Liang, Changsong Ding, Xindi Huang, Jianhua Huang, dan Qinghua Peng yang meneliti tentang Skalogram berbasis *Continuous Wavelet Transform (CWT)* digunakan untuk sinyal *photoplethysmography (PPG)* transformasi untuk mengklasifikasikan tekanan darah atau *Blood Pressure (BP)* dengan *Deep Learning*. Bertujuan untuk menyelidiki faktor-faktor penentu yang dapat meningkatkan akurasi klasifikasi BP berdasarkan PPG, *Deep Learning* dan membangun algoritma yang lebih baik untuk prediksi. Kumpulan data dari PhysioNet diakses untuk mengekstrak sinyal PPG mentah untuk pengujian dan BP terkaitnya sebagai label kategori. BP kategori normal atau abnormal mengikuti kriteria 2017 *American College of Cardiology/American Heart Association (ACC/AHA)* Pedoman Hipertensi. Sinyal PPG diubah menjadi 224 skalogram 3-piksel melalui perbedaan CWT dan unit segmen. Semuanya dimasukkan ke dalam *Convolutional Neural Network (CNN)* yang berbeda untuk pelatihan dan validasi. Karakteristik operasi penerima dan kurva kehilangan dan akurasi digunakan untuk mengevaluasi dan membandingkan kinerja berbagai metode. Hasil. Kedua jenis *wavelet* dan panjang segmen dapat mempengaruhi akurasi, dan *wavelet Cgaul* dan segmen-300 terungkap kinerja terbaik (akurasi 90%) tanpa overfitting yang jelas. Metode ini berkinerja lebih baik daripada yang penelitian sebelumnya *MATLAB Morse Wavelet* mengubah skalogram pada kedua CNN dan CNN-GoogLeNet yang peneliti usulkan. Kesimpulannya yaitu Peneliti membuat algoritma baru dengan akurasi tinggi untuk memprediksi klasifikasi BP dari PPG melalui pencocokan tipe dan segmen CWT panjang, yang merupakan solusi yang menjanjikan untuk prediksi cepat klasifikasi BP dari pemrosesan sinyal PPG waktu nyata pada perangkat yang dapat dipakai.[2]

Penelitian ini dilakukan oleh Wen-Fang Wang, Ching-Yu Yang, dan Yan-Fu Wu dengan mengembangkan sistem untuk mengidentifikasi kelebihan konsumsi alkohol. Elektrokardiogram (EKG) dan *Photoplethysmography (PPG)* sensor dan

inoxilyzers digunakan untuk mendapatkan sinyal tentang EKG, PPG, dan konsumsi alkohol tingkat peserta sebelum dan sesudah minum. Sinyal telah diproses sebelumnya, disegmentasi, dan dikenai untuk ekstraksi fitur menggunakan algoritma tertentu untuk menghasilkan Pelatihan dan data uji EKG dan PPG. Berdasarkan EKG, PPG, dan data konsumsi alkohol kami kembangkan dengan cepat dan skema identifikasi yang akurat menggunakan *Support Vector Machines* (SVM) algoritma untuk mengidentifikasi konsumsi alkohol. Pengklasifikasi SVM yang dioptimalkan dilatih menggunakan data pelatihan, dan data uji diterapkan untuk memverifikasi kinerja identifikasi SVM terlatih. Identifikasi kinerja pengklasifikasi yang diusulkan tercapai 95% rata-rata. Dalam penelitian ini, kombinasi fitur yang berbeda diuji untuk memilih teknologi yang optimal. Karena fitur PPG dan EKG menghasilkan kinerja klasifikasi yang identik dan fitur PPG lebih mudah untuk diperoleh, konfigurasi teknologi berdasarkan PPG pasti lebih disukai untuk dikembangkan perangkat pintar dan dapat dipakai untuk identifikasi *Driving Under the Influence* (DUI).[5]

Tabel 2. 1 Rangkuman Keterkaitan dengan Penelitian Sebelumnya

No	Peneliti	Judul	Atribut			
			Objek	Data Uji	Metode	Hasil Penelitian
1	Ernia Susana	Pengukuran Tekanan Darah <i>Non Invasive</i> Tanpa Manset Menggunakan Metode <i>Pulse Transit Time</i> Berbasis <i>Machine Learning</i> Multivariat Regresi	Tekanan Darah	Eksperimen -ECG - PPG	<i>Multivariat Regression</i>	Estimasi SBP = 0,7374 DBP = 0,0262
2	Leli Maharani	Implementasi dan Pengukuran Klasifikasi Tekanan Darah Berdasarkan <i>Pulse Transit Time</i> Menggunakan Metode Tranformasi <i>Wavelet</i> dan <i>Support Vector Mechine</i>	Tekanan Darah	Dataset - ECG - PPG	Klasifikasi <i>Support Vector Mechine</i> (SVM)	Akurasi = 91,67%,

3	Jiaze Wu, Hao Liang, Changsong Ding, Xindi Huang, Jianhua Huang, dan Qinghua Peng	<i>Improving the Accuracy in Classification of Blood Pressure from Photoplethysmography Using Continuous Wavelet Transform and Deep Learning</i>	Tekanan Darah	Dataset - PPG - ABP	Klasifikasi <i>Covolutional Neural Network (CNN)</i>	Akurasi CNN = 90,36%
4	Wen-Fang Wang, Ching-Yu Yang, dan Yan-Fu Wu	<i>SVM-based classification method to identify alcohol consumption using ECG and PPG monitoring</i>	Heart Rate Alcohol Consumption	Dataset - ECG - PPG	Klasifikasi <i>Support Vector Machine (SVM)</i>	Akurasi = 95%
5	Yulianto Tri Atmojo	Klasifikasi Tekanan Darah Dari Sinyal ECG dan PPG Menggunakan Metode <i>Wavelet Transform</i> dan <i>Random Forest</i>	Tekanan Darah	Dataset - ECG - PPG	Klasifikasi <i>Random Forest (Ensemble Bagged Trees)</i>	Akurasi = 96,7%


2.2 DASAR TEORI

2.2.1 TEKANAN DARAH

Tekanan darah adalah aktivitas otot jantung dan aliran darah secara keseluruhan dimana saat jantung memeriksa darah, otot jantung mengerut atau berkontraksi, sebaliknya saat jantung beristirahat, darah dari seluruh tubuh masuk ke jantung. Tekanan darah adalah gaya lateral pada dinding arteri oleh darah yang ditentukan oleh tekanan dari jantung. Aliran darah mengalir dalam sistem peredaran darah karena perubahan tekanan. Kontraksi jantung yang mendorong darah dengan tekanan tinggi dari aorta. Menurut Guyton, tekanan darah berarti diproduksi oleh darah per satuan luas dinding pembuluh. Satuan standar untuk mengukur tekanan darah adalah milimeter air raksa (mmHg). Mengukur sampai level berapa tekanan darah dapat mencapai kolom air raksa. Ketika seseorang mengatakan bahwa tekanan dalam pembuluh darah adalah 50 mmHg, itu berarti daya yang dihasilkan cukup untuk mendukung kolom air raksa melawan gravitasi hingga ketinggian 50 mm [6]. Menurut Potter & Perry, tekanan darah diklasifikasikan menjadi dua, yaitu tekanan darah sistolik dan tekanan darah diastolik:

a. *Systolic Blood Pressure (SBP)*


Tekanan darah sistolik adalah puncak dari tekanan maksimum saat ejeksi terjadi. Tekanan maksimum yang ditimbulkan di arteri setiap waktu darah disempatkan masuk ke dalam arteri selama sistol, atau tekanan sistolik, rata-rata adalah 120 mmHg.



Gambar 2. 1 Tekanan Darah Sistolik [7].

b. *Diastolic Blood Pressure (DBP)*

Tekanan darah diastolik adalah terjadinya tekanan minimal yang mendesak dinding arteri setiap waktu darah yang tetap dalam arteri menimbulkan tekanan. Tekanan minimum di dalam arteri sewaktu darah mengalir keluar selama diastol yakni tekanan diastolik, rata-rata tekanan diastol adalah 80 mmHg.



Gambar 2. 2 Tekanan Darah Diastolik [7].

Menurut *The Seventh Report of The Joint National Committee on Prevention, Detection, Evaluation, and Treatment of High Blood Pressure (JNC 7)* klasifikasi tekanan darah pada orang dewasa terbagi menjadi sebagai berikut :


Tabel 2. 2 Klasifikasi Tekanan Darah [8].

Kategori	SBP	DBP
Normal	<120	Dan <90
Prehipertensi	120-139	Atau 80-90
Hipertensi Stadium 1	140-159	Atau 90-99
Hipertensi Stadium 2	>160	Atau 100

Terdapat 2 cara pengukuran tekanan darah:

1. *Invasive Blood Pressure (IBP)*

Invasive Blood Pressure (IBP) atau adalah teknik yang umum digunakan di Unit Perawatan Intensif (ICU) dan juga sering digunakan di ruang operasi. Teknik ini melibatkan pengukuran langsung tekanan arteri dengan memasukkan jarum kanula ke dalam arteri yang sesuai. Kanula harus terhubung ke sistem steril berisi cairan, yang terhubung ke monitor pasien. Keuntungan dari sistem ini adalah bahwa tekanan darah pasien secara konstan dipantau detak demi detak, dan bentuk gelombang (grafik tekanan terhadap waktu) yang dapat ditampilkan.




Gambar 2. 3 Pengukuran Tekanan Darah
Secara Langsung [9].

2. *Non-Invasive blood pressure (NIBP)*

Teknik *non-invasive* adalah teknik pengukuran tekanan darah dengan menggunakan *cuff* (manset). Teknik *non-invasive* terdiri dari metode osilometrik dan dan auskultasi. Saat ini, pengukuran dengan teknik *non-invasive* digunakan secara luas karena tidak melukai pasien tetapi tetap menimbulkan ketidaknyamanan berupa timbulnya rasa sakit akibat meningkatnya tekanan dari aktifitas pemompaan manset. *Oscillometri* memanfaatkan tekanan osilasi dalam manset dan dicatat dalam deflasi bertahap. Kalibrasi pada alat NIBP pasien monitor dapat dilakukan dengan dua metode yaitu metode *static* dan metode *dynamic*, sedangkan auskultasi dengan mendengarkan muncul dan hilangnya bunyi Korotkoff pada arteri brakialis. Kedua teknik pengukuran *non-invasive* diatas membutuhkan pengawasan dan

persiapan khusus serta menimbulkan ketidaknyamanan bagi pasien selama pemeriksaan berlangsung. Pengembangan metode pengukuran *non-invasive* tekanan darah terus dikembangkan hingga kini. Salah satunya adalah metode PTT.



Gambar 2. 4 Pengukuran Tekanan Darah Menggunakan *Sphygmomanometer* [10].

2.2.2 ARTERIAL BLOOD PRESSURE

Pembuluh darah merupakan bagian dari sistem sirkulasi tubuh manusia. Fungsinya adalah untuk mengalirkan darah dari jantung ke seluruh tubuh dan mengangkut darah dari seluruh tubuh menuju jantung. Selain itu, pembuluh darah juga berkontribusi dalam pengaturan tekanan darah.

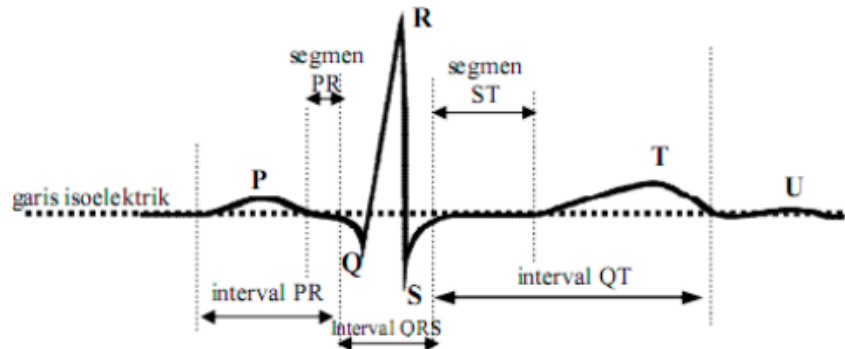
Di dalam tubuh terdapat tiga pembuluh darah utama, yaitu:

1. Pembuluh Nadi (Arteri)
2. Pembuluh Balik (Vena)
3. Pembuluh Kapiler [11].

2.2.3 EKG

Elektrokardiograf adalah instrumen elektronik medis untuk mengukur potensi bioelektrik yang disebabkan oleh aktivitas listrik otot jantung. Arus listrik

terjadi ketika otot jantung berkontraksi dan menghasilkan medan listrik yang berubah seiring waktu. Hal ini mengakibatkan munculnya potensi bioelektrik di kulit manusia. Elektroda yang menempel pada kulit yang memiliki potensi listrik ini digunakan sebagai input untuk instrumen EKG. Sinyal yang ditangkap elektroda adalah sinyal bioelektrik [12].



Gambar 2. 5 Gelombang EKG Normal [13]

Terdapat 12 nilai yang memiliki arti klinis dari grafik keluaran EKG untuk menentukan kriteria kelainan, yaitu : Irama, Frekuensi, Amplitudo gelombang P, Durasi gelombang P, Interval PR, Interval QRS, Interval Q, Amplitudo R, Segmen ST, Interval QTc, Amplitudo T, dan Keteraturan

Gelombang EKG normal memiliki ciri-ciri sebagai berikut:

1. Gelombang P mempunyai amplitudo kurang dari 0,3 mV dan perioda kurang dari 0,11 detik.
2. Gelombang Q mempunyai amplitudo sebesar minus 25% dari amplitudo gelombang R.
3. Gelombang R mempunyai amplitudo maksimum 3 mV.
4. Gelombang S merupakan defleksi negatif sesudah gelombang R.
5. Kompleks QRS terdiri dari gelombang Q, R dan S yang memiliki perioda 0,06-0,10 detik dengan perioda rata-rata 0,08 detik.
6. Gelombang T mempunyai amplitudo minimum 0,1 mV.

Salah satu metode pengambilan sinyal ECG yang biasa digunakan untuk menganalisis kondisi kesehatan jantung pasien mengacu pada *Clinical Guidelines by Consenses* yang dikeluarkan oleh *British Cardiovascular Society* [10], yaitu dengan menggunakan sepuluh buah elektroda dengan dua belas titik sadapan (12 leads). Sepuluh buah elektroda tersebut dihubungkan ke tubuh manusia yaitu, *Right*


Arm (RA), Left Arm (LA), Left Leg (LL), AVF, Right Leg (RL), Chest I (C1), C2, C3, C4, C5 dan C6.

Fungsi sadapan ECG adalah untuk menghasilkan sudut pandang yang jelas terhadap jantung. Sadapan ini dibaratkan dengan banyaknya mata yang mengamati jantung dari berbagai arah. Semakin banyak sudut pandang, semakin sempurna pengamatan terhadap kerusakan-kerusakan bagian-bagian jantung [14].

2.2.4 PPG

Photoplethysmography adalah teknik optik *non-invasive* untuk mengukur perubahan volume darah berdasarkan variasi intensitas cahaya yang lewat atau dipantulkan oleh organ tubuh manusia. Cahaya yang dipancarkan pada jaringan tubuh dapat diserap oleh substansi yang berbeda-beda, misalnya pigmen kulit, tulang, darah arteri dan vena. Perubahan aliran darah paling banyak terdapat pada arteri dan arterioles. *Photoplethysmography* menggunakan sumber cahaya dari LED (*Light Emitting Diode*) dan PD (*Photodetector*) untuk mendeteksi adanya perubahan volume darah dalam pembuluh darah. Cahaya dapat ditransmisikan melalui jaringan kapiler (*capillary bed*). Saat pulsasi arteri (*arterial pulsations*) mengisi jaringan kapiler, perubahan volume pembuluh mengubah penyerapan (*absorption*), pantulan (*reflection*), dan hamburan (*scattering*) cahaya.

Sinyal PPG secara umum memiliki bentuk yang berbeda dengan sinyal ECG. Namun terdapat kesesuaian pola sinyal yang mampu menunjukkan R-R interval. Kesesuaian pola sinyal PPG dan ECG ditunjukkan pada Gambar dibawah 2.4.




Gambar 2. 6 Gelombang Sinyal PPG [15].

PPG memiliki dua mode, yaitu mode transmisi dan mode reflektansi seperti yang terlihat pada Gambar 2.7. Pada mode transmisi, cahaya yang ditransmisikan melalui medium atau jaringan tubuh terdeteksi oleh PD berlawanan sumber LED.

Mode transmisi ini mampu memperoleh sinyal relatif lebih baik, tetapi tempat pengukurannya terbatas.

Agar efektif, sensor mode transmisi harus terletak pada tubuh pada bagian di mana cahaya yang ditransmisikan dapat segera dideteksi, seperti jari, septum hidung, pipi, lidah, atau daun telinga. Sementara dalam mode reflektansi, PD mendeteksi cahaya yang kembali tersebar atau dipantulkan dari jaringan, tulang dan atau pembuluh darah. Mode reflektansi menghilangkan masalah yang terkait dengan penempatan sensor, dan berbagai tempat pengukuran yang dialiri darah dapat digunakan. Sehingga pengguna bisa menggunakan perangkat PPG dimanapun tempatnya seperti pergelangan tangan.



Gambar 2. 7 Aliran Arteri pada Jari [15].

2.2.5 PTT

Waktu transit nadi (*Pulse Transit Time*) adalah interval waktu untuk nadi arteri gelombang tekanan untuk melakukan perjalanan dari katup aorta di mana ia dikeluarkan dari ventrikel kiri ke situs perifer. Situs perifer dapat di mana saja di sepanjang arteri brakialis dimana denyut nadi paling terasa. Arteri brakialis adalah pembuluh darah utama lengan atas, jadi untuk arteri yang tersumbat saat mengukur tekanan darah menggunakan tensimeter air raksa tradisional. PTT adalah waktunya interval antara dua pulsa terdeteksi pada arteri yang sama. Biasanya, PTT didefinisikan sebagai interval waktu antara dua titik karakteristik – puncak R dari elektrokardiogram (EKG) dan puncak denyut nadi di jari tangan, daun telinga, atau kaki. Jadi PTT diukur dengan memantau EKG dan gelombang *Pulse*. EKG digunakan untuk menentukan waktu di mana darah meninggalkan katup aorta. Puncak R digunakan sebagai penanda untuk waktu ketika darah meninggalkan katup aorta. Dengan bertambahnya dalam kecepatan darah maka BP akan meningkat yang berarti darah mencapai situs perifer dari katup aorta dalam waktu yang lebih singkat yang berarti waktu transit lebih sedikit dan penurunan BP sesuai dengan PTT yang lebih lama.

PTT didefinisikan sebagai waktu yang dibutuhkan antara puncak sinyal ECG (Gelombang puncak R) menuju puncak sinyal PPG. Dari definisi tersebut, PTT dapat dituliskan seperti Persamaan 2.1.

$$PTT = t_{RPPG} - t_{RECG} \quad (2.1)$$

Keterangan :


- PTT = Pulse Transit Time
- t_{RPPG} = Waktu rata-rata saat terjadi puncak PPG (detik)
- t_{RECG} = Waktu rata-rata saat terjadi puncak ECG (detik)

Ketika jantung mengalirkan darah, aliran darah yang diedarkan memiliki kecepatan untuk sampai ke tubuh. Untuk beberapa bagian tubuh, seperti ujung jari merupakan organ yang bisa dideteksi karena bisa menghasilkan gelombang yang kuat. Kecepatan tekanan darah disebut *Pulse Wave Velocity* (PWV) dimana PWV dapat dihitung dari jarak antara jantung ke jari dengan nilai PTT. Berikut dapat dituliskan pada persamaan 2.2.

$$PWV = \frac{(BDC \times Height)}{PTT} \quad (2.2)$$

Keterangan :

- PWV = *Pulse Wave Velocity*
- BDC = *Body Correlation Factor*, BDC bernilai 0,5 untuk dewasa
- Height = Tinggi Badan (cm)



Gambar 2. 8 Definisi PTT [16].

PWV dapat berdampak pada tekanan darah seseorang. Apabila PWV berubah maka waktu untuk jantung berkontraksi dan berelaksasi akan berubah juga sehingga tekanan sistolik dan diastolnya juga akan berubah. PWV digunakan untuk mencari nilai tekanan sistolik dan diastolik melalui persamaan *linear*. Semakin tinggi kecepatan tekanan darah maka tekanan darahnya juga semakin tinggi, hal itu dikarenakan jantung lebih cepat dalam melakukan pemompaan darah.

Untuk mengetahui besarnya tekanan darah dapat dicari dengan Persamaan (2.3)

$$\text{Tekanan darah} = a * PWV + b \quad (2.3)$$

Keterangan :

a = Koefisien X Linear Reggresi

b = Koefisien Y Linear Regresi

PWV = Pulse Wave Velocity

Dimana untuk tekanan sistolik, a bernilai 0.05089855 dan b bernilai 62.5590972 sedangkan untuk mengukur tekanan diastolik a bernilai 0.04940772 dan b bernilai 17.4800472 [16].

2.2.6 Transformasi *Wavelet*

Kata *Wavelet* dikemukakan oleh Morlet dan Grossmann pada awal tahun 1980, dalam bahasa Prancis *ondelette*, yang berarti gelombang kecil. Dan setelah itu dalam bahasa Inggris kata *onde* diganti menjadi *wave* sehingga menjadi *Wavelet*. Transformasi *wavelet* merupakan suatu transformasi *linear* yang hampir mirip dengan Transformasi *Fourier*, dengan satu perbedaan penting: transformasi *wavelet* membolehkan penempatan waktu dalam komponen-komponen frekuensi yang berbeda dari sinyal yang diberikan.

Untuk menganalisa sinyal yang frekuensinya bervariasi pada satuan waktu, diperlukan suatu transformasi yang dapat memberikan resolusi frekuensi dan waktu disaat yang bersamaan, biasa disebut analisis multi resolusi (AMR). AMR dirancang untuk memberikan resolusi waktu yang baik dan resolusi frekuensi yang kurang baik pada frekuensi tinggi suatu sinyal, serta resolusi frekuensi yang baik dan resolusi waktu yang kurang baik pada frekuensi rendah suatu sinyal. Transformasi *wavelet* memiliki beberapa keistimewaan unik yang membuatnya sangat cocok untuk aplikasi khusus ini. Tidak seperti fungsi-fungsi dasar yang

digunakan dalam analisa *Fourier*, *wavelet* tidak hanya dibatasi pada frekuensi tapi juga pada waktu. Pembatasan atau penempatan ini memperhitungkan deteksi waktu dari kejadian gangguan-gangguan yang terjadi secara tiba-tiba, seperti gangguan transien. Aturan dari multi resolusi ini sangat berguna untuk menganalisa gangguan transien yang mengandung komponen- komponen frekuensi tinggi yang dilokalisir pada sinyal-sinyal frekuensi daya.

Analisis *wavelet* adalah sebuah teknik penjendelaan variabel (*variable windowing technique*) dan mengijinkan penggunaan interval waktu yang panjang dimana kita menginginkan informasi frekuensi rendah yang lebih tepat, dan daerah atau wilayah yang lebih pendek dimana kita menginginkan komponen- komponen frekuensi yang lebih tinggi.

Secara garis besar transformasi wavelet terbagi dua yaitu : transformasi wavelet kontinyu dan transformasi wavelet diskrit.

2.2.7 *Discrete Wavelet Transform*

Dibandingkan dengan CWT (*Continuous Wavelet Transform*), transformasi *wavelet* diskrit (DWT) dianggap relatif lebih mudah pengimplementasiannya. Prinsip dasar dari DWT adalah bagaimana cara mendapatkan representasi waktu dan skala dari sebuah sinyal menggunakan teknik pemfilteran digital dan operasi sub-sampling.

Untuk bentuk DWT, persamaan yang diberikan adalah:

$$DWT(m,n) = \sum (a_0^{m-0,5})f(k)[\Psi((n - ka_0^m)/(a_0^m))] \quad (2.4)$$

Keterangan :

DWT = Transformasi Wavelet Diskrit

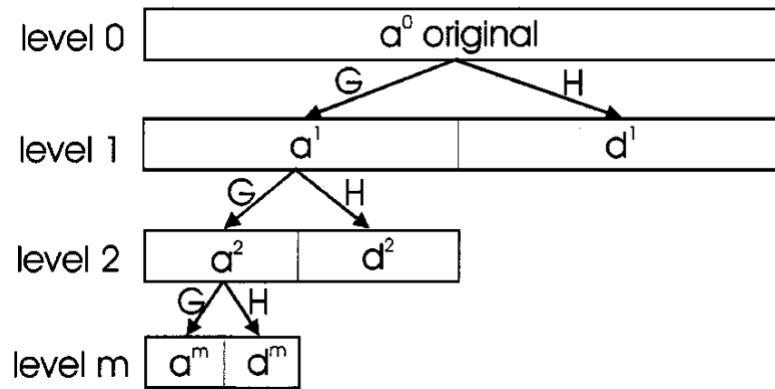
$\Psi(k)$ = Fungsi *wavelet*

$f(k)$ = Sinyal asli atau original

a_0^m = Konstanta skala

ka_0^m = Transmisi dan

k,n = Variabel integer



Gambar 2. 9 Dekomposisi Wavelet [17].

Wavelet dibentuk menggunakan filter FIR *low-pass* dan *high-pass*. Keluaran dari filter *low-pass* dan *high-pass* ini dapat dinyatakan secara matematis :

$$C_j[k] = \sum u[m] \cdot g[2k - m] \quad (2.5)$$

$$D_j[k] = \sum u[m] \cdot h[2k - m] \quad (2.6)$$

Keterangan :

- C_j = Aproksimasi
- D_j = Koefisien Detail
- u = Dekomposisi Wavelet
- g = Koefisien Low Pass Filter
- h = Koefisien High Pass Filter
- m = Level Dekomposisi

Invers TWD kemudian digunakan untuk membangun kembali sinyal ke sinyal asli dengan tidak kehilangan informasi. Keluaran dari filter *low-pass* dan *high-pass* dalam tahap rekonstruksi sinyal dapat dinyatakan pada persamaan :

$$u[m] = \sum \{C_j(k) \cdot g[2k - m] + D_j(k) \cdot h[2k - m]\} \quad (2.7)$$

2.2.8 *Thesholding*

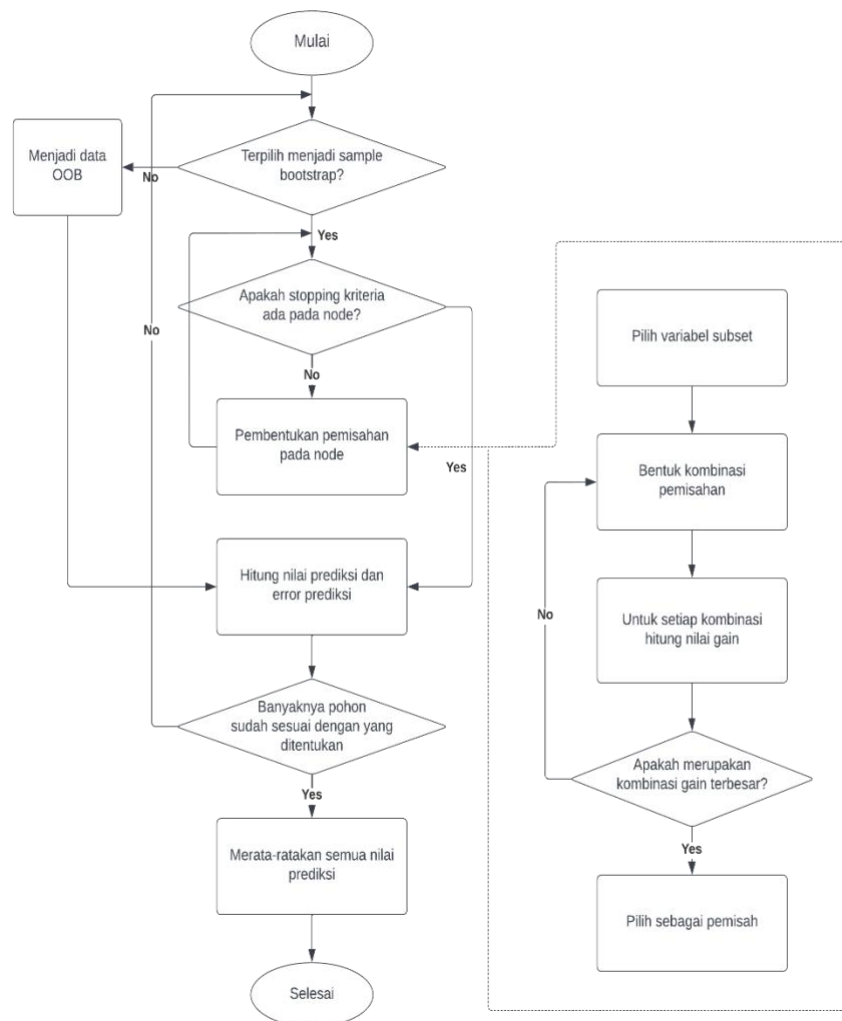
Berdasarkan sifat dasar transformasi wavelet, diketahui bahwa tingkat resolusi yang lebih halus (tahap dekomposisi yang lebih tinggi) akan hanya memuat informasi detail dan memberikan sinyal rata-rata dalam resolusi yang lebih kasar. Oleh karena itu, dengan menghapus tingkat resolusi yang paling halus, dan merekonstruksinya kembali akan diperoleh pengaruh penghalusan seperti penerapan filter linear yang sangat elementer. Dalam hal ini noise dapat tereduksi, tetapi kemungkinan juga akan mengakibatkan mengaburnya sinyal asal. Telah diketahui pula bahwa kebanyakan koefisien wavelet adalah sangat kecil. Akan tetapi, masing-masing tahap dekomposisi menghasilkan koefisien-koefisien yang membawa sifat-sifat yang berbeda sesuai dengan tingkat resolusinya. Untuk itu, perlakuan pada koefisien-koefisien pada masing-masing tahap dekomposisi perlu dicermati dan seharusnya diperlakukan berbeda.

2.2.9 *Random Forest*

Algoritma *Random Forest* pertama kali diusulkan oleh Breiman. Algoritma *Random Forest* dapat digunakan untuk menyelesaikan persoalan klasifikasi dan juga regresi selain itu, *Random Forest* dapat digunakan untuk berbagai jenis variabel respon seperti kontinu, diskrit, data survival maupun data kombinasi multivariat. Metode ini dapat mengestimasi berbagai bentuk fungsi yang terbentuk antara variabel respon dan variabel penjelas yang mempermudah menentukan hubungan *non-linear* kompleks yang mungkin akan sulit ditemukan tanpa adanya spesifikasi tertentu dan tanpa menggunakan standar metode tertentu. Intinya, *Random Forest* dapat dan mampu mendeteksi berbagai interaksi antara respon dan prediktor. Dengan fleksibilitas dari *Random Forest*, membuat metode ini sangat berguna sebagai metode eksplorasi data. *Random forest* biasa juga disebut sebagai metode *ensemble* atau metode gabungan. Disebut metode gabungan karena terbentuk dari model-model kecil namun hasil prediksinya ditentukan dengan mengkombinasikan semua *output* pada model kecil tersebut atau yang bisa disebut sub-model. Sub-model pada metode *Random Forest* adalah *Classification and Regression Trees* (CART) [18].

Metode *Random Forest* merupakan pengembangan dari metode CART, yaitu dengan menerapkan metode *Bootstrap Aggregating* (bagging) dan *Random*

Feature Selection. Dalam *Random Forest*, banyak pohon ditumbuhkan sehingga terbentuk hutan (*forest*), kemudian analisis dilakukan pada kumpulan data yang terdiri dari n amatan dan p peubah penjelasan. Sehingga dengan kata lain, *Random Forest* adalah metode yang merupakan gabungan dari CART. Oleh karena itu, sebelum membahas algoritma *Random Forest*, terlebih dahulu dibahas mengenai *Classification and Regression Trees (CART)*. Berikut algoritma *random forest* terdapat pada gambar 2.10.



Gambar 2. 10 Flowchart Algoritma *Random Forest* [19].

2.2.10 Classification and Regression Trees (CART)

CART merupakan metode eksplorasi data yang didasarkan pada teknik pohon keputusan. Pohon Klasifikasi dihasilkan saat peubah respons berupa data

kategorik, sedangkan pohon regresi dihasilkan saat peubah respons berupa data numerik.

Pengelompokkan pada CART ini bekerja dengan cara menentukan variabel prediktor dan nilai pemisahan nya yang merupakan nilai pada prediktor tersebut untuk dijadikan sebagai kandidat pemisahan. Pada setiap pemisahan yang dibentuk, dihitung berapa error yang dihasilkan jika variabel prediktor beserta nilai pemisahnya dijadikan sebagai kriteria pemisahan. Untuk memilih variabel mana yang dijadikan sebagai pemisahan, dipilih dengan menghitung penurunan *error* yang didapatkan jika variabel tersebut dijadikan sebagai variabel pemisah [20].

2.2.11 Algoritma *Random Forest*

Random Forest adalah Pengembangan dari metode CART atau dengan kata lain *Random Forest* adalah metode gabungan (*ensemble*). Berikut ini adalah algoritma dari *Random Forest*.

1. Tahap *Bootstrap*

Tahap *Bootstrap* dilakukan untuk mendapatkan model kecil (*submodel*) pada *Random Forest* bukan dengan melakukan penaksiran pada semua data yang ada tetapi sampel *Bootstrap* dari data asli. Data hasil *Bootstrap* dinamakan data *Out of Bag* atau yang biasa disebut OOB. Data OOB berfungsi untuk menghitung nilai prediksi pada masing-masing CART. Hasil prediksi dari model CART dihasilkan dari memasukkan data OOB ke dalam pohon yang telah terbentuk dari sampel *Bootstrap*. Sehingga, setiap observasi memiliki nilai prediksi yang dihasilkan dari setiap pohon CART data tersebut tidak menjadi sampel *Bootstrap* pada pohon tersebut dan akan mengurangi resiko *Overfitting* yang ditimbulkan dari CART.

2. Penumbuhan CART pada setiap Sampel *Bootstrap*

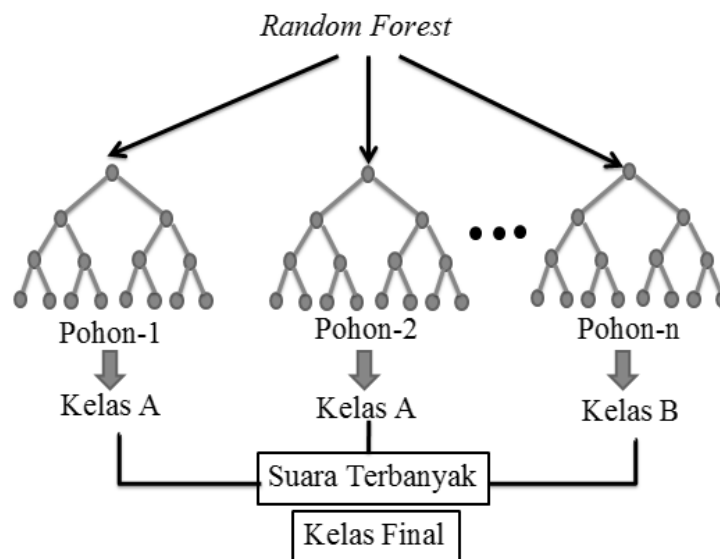
Setelah dilakukan *re-sampling bootstrap* dari data asli, maka selanjutnya menumbuhkan pohon CART dari sampel *Bootstrap*. Prosedur pemilihan variabel pemisahan dan nilai pemisahan pada CART ditentukan dengan besarnya penurunan *error* atau *gain* yang dihasilkan.

Pemilihan variabel pemisah dari semua variabel penjelas yang ada pada data asli, hanya variabel penjelas yang terpilih pada *random subset* yang bisa dijadikan sebagai variabel pemisah. Banyaknya jumlah variabel penjelas yang terdapat pada pemilihan *random subset* dinotasikan (m). Nilai m yang dijadikan standar untuk

regresi adalah $p/3$ ini tidak berlaku untuk semua kasus dan ukuran minimum node adalah 5. Menurut Breimen default yang digunakan untuk m *try* adalah 5. Variabel penjelas yang menghasilkan nilai penurunan *error* terkecil setelah dilakukan *random subset* pada variabel penjelas memiliki kesempatan lebih besar untuk terpilih menjadi variabel pemisah.

3. Tahap Prediksi

Didalam regresi tahapan prediksi menjadi penting untuk mengetahui model terbaik. Semakin dekat dengan data asli maka hasil prediksi semakin baik. Untuk satu data observasi dapat menjadi data OOB berulang kali, sehingga dengan kata lain data tersebut masuk ke dalam pohon yang diestimasi. Pada regresi *Random Forest*, nilai prediksi yang dihasilkan dari kumpulan pohon adalah rata-rata nilai prediksi pada setiap pohonnya.



Gambar 2. 11 Ilustrasi *Random Forest* [21].

Random forest melakukan pendugaan gabungan (*aggregating*) hasil prediksi k pohon. Kasus klasifikasi pohon yang dibangun adalah hasil prediksi random forest berdasarkan suara terbanyak (*majority vote*) yaitu kategori yang sering muncul pada k buah pohon merupakan hasil prediksi keseluruhan. Ilustrasi tahapan pada *random forest* secara umum dapat dilihat pada Gambar 2.11 [21].

2.2.12 *Confusion Matrix*

Confusion matrix adalah suatu metode yang biasa digunakan untuk melakukan perhitungan akurasi pada konsep *data mining*. *Confusion Matrix* memiliki informasi hasil prediksi dan aktual pada data yang telah di klasifikasi. Performa suatu sistem biasanya dievaluasi menggunakan *Confusion Matrix*

Tabel 2. 3 *Confusion Matrix* Dua Kelas [22].

Aktual	Hasil Prediksi	
	+	-
+	True Positive (TP)	True Negative (TN)
-	False Positive (FP)	False Negative (FN)

Metode ini menghasilkan beberapa nilai yang digunakan sebagai evaluasi performa model yaitu *f1 score*, *accuracy*, *precision* dan *recall*. TP yaitu jumlah *tuple* positif yang dilabeli dengan benar oleh model klasifikasi. TN yaitu jumlah *tuple* negatif yang dilabeli benar oleh model klasifikasi. FP yaitu jumlah *tuple* negatif yang salah dilabeli oleh model klasifikasi dan FN yaitu jumlah *tuple* positif salah dilabeli oleh model klasifikasi.

Perhitungan nilai akurasi sebuah model dapat dilihat pada persamaan (2.9). Akurasi merupakan tingkat identifikasi yang menghasilkan persentase dari jumlah data uji diklasifikasi dengan benar [22].

$$Accuracy = \frac{TP}{Total\ Data} \quad (2.9)$$