

## SISTEM PENDETEKSI *SLEEP-DISORDERED BREATHING* BERDASARKAN *HIGH* DAN *LOW FREQUENCY* MENGGUNAKAN METODE *NAÏVE BAYES*

Achmad Ghifari<sup>1</sup>, Edita Rosana Widasari<sup>\*2</sup>

<sup>1,2</sup>Universitas Brawijaya, Malang  
Email: <sup>1</sup>aghifari@student.ub.ac.id, <sup>2</sup>editarosanaw@ub.ac.id  
\*Penulis Korespondensi

(Naskah masuk: 09 Januari 2023, diterima untuk diterbitkan: 07 Agustus 2023)

### Abstrak

Tidur merupakan aktivitas dimana otak memberikan tubuh waktu istirahat secara total. Kualitas tidur penting untuk menjaga kondisi fisik maupun mental seseorang. Buruknya kualitas tidur disebabkan oleh gangguan tidur. Gangguan tidur yang paling umum terjadi adalah *Sleep-disordered Breathing* (SDB) atau *Sleep Apnea*, dimana penderitanya akan mengalami henti napas secara berulang saat tertidur. *Sleep Apnea* dikategorikan menjadi 2, yaitu *Obstructive Sleep Apnea* (OSA) dan *Central Sleep Apnea* (CSA). Diagnosis gangguan tidur dilakukan dengan *Polysomnography* yang cenderung mahal dan kurang nyaman. Hasil *Polysomnography* juga tidak dapat langsung digunakan oleh dokter untuk evaluasi lebih lanjut. Oleh karena itu, pada penelitian ini dibuat sistem pendeteksi gangguan tidur ke dalam kelas Normal, OSA, atau CSA menggunakan sinyal *Electrocardiography* (ECG) yang diakuisisi dengan teknik *3-lead placement*. Sistem ini menggunakan sensor AD8232 dalam mengakuisisi sinyal jantung yang akan diproses oleh Arduino Mega 2560 untuk mendapatkan fitur *High* dan *Low Frequency* dari sinyal yang kemudian digunakan untuk klasifikasi. Sistem ini memiliki akurasi sebesar 85% dalam melakukan klasifikasi SDB menggunakan metode *Naive Bayes* dengan rata-rata waktu komputasi sebesar 12ms. Sistem ini dapat digunakan di rumah karena bersifat *portable* dan datanya dapat langsung diunduh melalui *website* untuk evaluasi dokter, sehingga membuat pasien merasa lebih nyaman dan efisien dalam melakukan diagnosis dini.

**Kata kunci:** *ECG, High Frequency, Low Frequency, Naive Bayes, Sistem Pendeteksi, Sleep-disordered Breathing*

## ***SLEEP-DISORDERED BREATHING DETECTION SYSTEM BASED ON HIGH AND LOW FREQUENCY USING NAÏVE BAYES CLASSIFIER***

### Abstract

*Sleep is an activity in which the brain gives the body total rest. The quality of sleep is important to maintain someone's physical and mental condition. Poor sleep quality is caused by sleep disorders. The most common sleep disorder is Sleep-Disordered Breathing (SDB) or Sleep Apnea, in which the sufferer will experience repeated pauses in breathing while asleep. Sleep Apnea is categorized into two, namely Obstructive Sleep Apnea (OSA) and Central Sleep Apnea (CSA). Sleep disorder diagnosis is done with Polysomnography which is expensive and uncomfortable. The result of Polysomnography can also not be directly used by doctors for further evaluation. Therefore, in this research, a system was created to detect sleep disorders into Normal, OSA, or CSA classes using Electrocardiography (ECG) signals acquired by the 3-lead placement technique. This system uses AD8232 sensors to acquire heart signals that are processed by Arduino Mega 2560 to obtain High and Low-frequency features of the signal, which are then used for classification. This system has an accuracy of 85% in classifying SDB using the Naive Bayes method with an average computation time of 12ms. This system can be used at home because it is portable and the data can be directly downloaded from the website for doctor evaluation, making the patient feel more comfortable and efficient in early diagnosis.*

**Keywords:** *Detection System, ECG, High Frequency, Low Frequency, Naive Bayes, Sleep-disordered Breathing*

### 1. PENDAHULUAN

Tidur merupakan salah satu aktivitas manusia dimana otak memberikan tubuh waktu untuk beristirahat secara total. Saat seseorang tertidur,

hormon pertumbuhan dilepaskan oleh kelenjar bawah otak untuk membantu regenerasi sel dan pertumbuhan tubuh (Queens Health, 2018). Oleh karena itu, tidur menjadi salah satu kebutuhan biologis manusia selain makanan, air, dan udara

(Grandner, 2017). Sampai saat ini, kualitas tidur dipercaya penting bagi kesehatan dan kesejahteraan manusia (Simonelli, et al., 2018). Terdapat beberapa penyebab kurangnya tidur seseorang, salah satunya adalah gangguan tidur.

Di Indonesia, Dr. Welly Sondakh, MPH menyatakan bahwa terdapat 28 juta orang atau lebih dari 10% populasi Indonesia menderita gangguan tidur (Abidin, et al., 2019). Menurut *International Classification of Sleep Disorders 3 (ICSD-3)*, jenis gangguan tidur manusia meliputi *Insomnia, Sleep-disordered breathing, Central disorders of hypersomnolence, Circadian rhythm sleep-wake disorders, Parasomnias, dan Sleep-related movement disorders* (Sateia, 2014). Berdasarkan analisis literatur yang dilakukan oleh (Benjafeld et al., 2019), *Sleep-disordered breathing* merupakan salah satu gangguan tidur yang paling banyak dialami manusia, dengan jumlah penderita sekitar 1 miliar dari 7.3 miliar populasi dunia. *Sleep-disordered breathing* atau *Sleep Apnea* dibedakan menjadi dua, yaitu *Obstructive Sleep Apnea (OSA)* dan *Central Sleep Apnea (CSA)* (Wells, 2018).

Apnea merupakan gangguan dimana pernapasan seseorang berhenti setidaknya selama 10 detik, dimana OSA merupakan kondisi dimana otot pernapasan yang terletak di belakang tenggorokan terlalu rileks sehingga dapat menyebabkan tersumbatnya saluran pernapasan ketika seseorang tidur, sedangkan CSA adalah kondisi ketika otot yang mengontrol pernapasan tidak mendapatkan sinyal yang dikirimkan otak dengan baik sehingga seseorang akan mengalami henti napas selama beberapa detik.

*Polysomnography* digunakan dalam melakukan diagnosis gangguan tidur, dimana pasien akan menginap di rumah sakit dan menggunakan banyak elektroda untuk mengukur berbagai macam parameter biomedis seperti *Electroencephalography (EEG)*, *Electrooculography (EOG)*, *Electroencephalography (ECG)*, *Electromyography (EMG)*, posisi tubuh, saturasi oksigen, aliran udara, dan upaya pernapasan dada serta perut, sehingga pengukuran ini cenderung mahal dan tidak nyaman. Hasil dari pengukuran ini juga tidak dapat langsung digunakan oleh dokter untuk melakukan evaluasi karena butuh waktu untuk mendapatkannya. Oleh karena itu, dibutuhkan teknik dengan pengukuran yang dapat dilakukan di rumah untuk mendiagnosis *Sleep Apnea* (Hung, 2018).

Pada penelitian sebelumnya oleh (Koza, et al., 2021) dibuat sistem deteksi OSA berdasarkan sinyal ECG dengan teknik penempatan elektroda *3-lead placement* menggunakan metode *Naïve Bayes* menunjukkan performa yang sangat baik, yaitu diperoleh akurasi sebesar 87,5% dari 24 data uji.

Penelitian lain yang dilakukan oleh (Szollosi, et al., 2007) menunjukkan bahwa fitur domain frekuensi dari HRV yaitu *High Frequency (HF)* dan *Low Frequency (LF)* memiliki ciri yang berbeda pada

pasien dengan OSA dan CSA, dimana HF meningkat pada penderita OSA dan semakin kecil pada penderita CSA, sedangkan LF cenderung sama.

Berdasarkan literatur dan penelitian sebelumnya, pada penelitian ini dibuat sistem pendeteksi *Sleep-disordered Breathing* menggunakan fitur HF dan LF serta metode *Naïve Bayes* untuk klasifikasi ke dalam kelas Normal, OSA, atau CSA. Sistem ini akan menggunakan sensor AD8232 sebagai *input* yang akan diproses oleh Arduino Mega 2560 sebelum ditampilkan pada *website* dan LCD. *Output* dari sistem juga dapat langsung diunduh dalam bentuk catatan berisi fitur serta hasil klasifikasi untuk mempercepat dan memudahkan dokter dalam melakukan evaluasi serta diagnosis terhadap pasien.

## 2. METODE PENELITIAN

### 2.1 Gambaran Umum Sistem

Keseluruhan pemrosesan pada sistem ini dilakukan dalam 2 perangkat, yaitu laptop dan Arduino. Diagram blok keseluruhan sistem dapat dilihat pada Gambar 1.

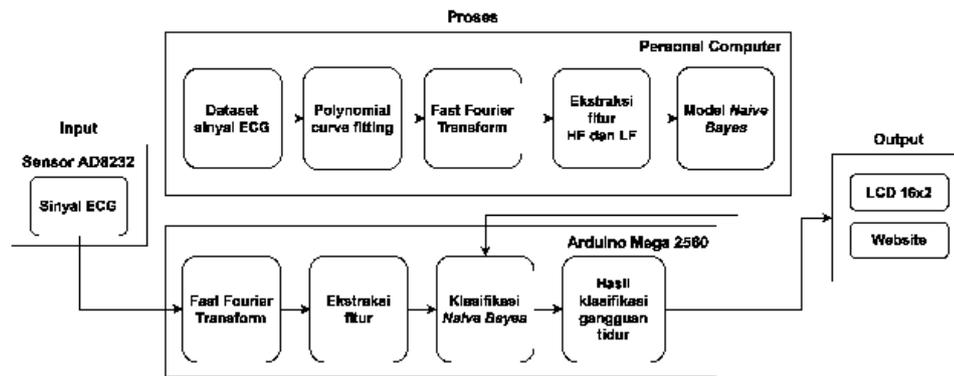
Proses ekstraksi fitur dari data latih dan *training* data akan dilakukan di laptop menggunakan Matlab, sedangkan untuk proses deteksi akan dilakukan oleh Arduino Mega 2560 yang mendapatkan *input* dari sensor AD8232 yang berupa sinyal ECG. Sinyal ECG kemudian akan diproses oleh Arduino berupa transformasi sinyal domain waktu ke domain frekuensi menggunakan FFT, ekstraksi fitur, hingga klasifikasi menggunakan metode *Naïve Bayes* ke dalam kelas Normal, OSA, dan CSA. Hasil pemrosesan ini kemudian akan ditampilkan pada LCD berupa hasil klasifikasi dan dikirimkan ke *server* untuk disimpan pada *database* dan ditampilkan di *website*.

### 2.2 Teknik Pengumpulan Data

Pengumpulan data dilakukan secara langsung dengan pengujian untuk data subjek normal menggunakan modul sensor AD8232, dimana subjek akan terlebih dahulu mengisi kuesioner *Epworth Sleepiness Scale (ESS)* dan *STOP-Bang* untuk kondisi kantuk serta risiko subjek terhadap *Apnea*. Sedangkan untuk data subjek dengan kondisi menderita OSA dan CSA, penulis menggunakan basis data online yang terdapat di <https://physionet.org/content/ucddb/1.0.0/>. Rincian subjek pada penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Subjek Pengujian

Parameter	Data Latih	Data Uji
Gender (L/P)	5/2	10/4
Jumlah	7	14
Usia	±40 Tahun	±27,7 Tahun
Berat	±90,24 kg	±61 kg
Tinggi	±175,71 cm	±171,2 cm



Gambar 1. Diagram Blok Keseluruhan Sistem

Didapatkan data sebanyak 4855 *epoch* dari 7 subjek yang terdiri atas 2314 data Normal, 1380 Apnea-C, dan 1161 Apnea-O.

### 2.3 Fast Fourier Transform

*Fast Fourier Transform* atau FFT digunakan untuk mengubah sinyal domain waktu ke domain frekuensi agar sistem dapat mengekstraksi fitur domain frekuensi dari sinyal *input*nya. Rumus FFT dapat dilihat pada Persamaan (1).

$$S(f) = \int_{-\infty}^{\infty} s(t)e^{-j2\pi ft} dt \quad (1)$$

Dimana,

$S(f)$	=	Sinyal domain frekuensi
$s(t)$	=	Sinyal domain waktu
$e^{-j2\pi ft}$	=	Konstanta sinyal
$f$	=	Frekuensi
$t$	=	Waktu

### 2.4 Ekstraksi Fitur

Fitur yang digunakan sebagai parameter klasifikasi pada penelitian ini adalah *High* (HF) dan *Low Frequency* (LF) dari sinyal ECG yang diakuisisi. Nilai HF merupakan nilai *power* atau amplitudo yang terdapat pada rentang frekuensi 0.15 Hz – 0.4 Hz, sedangkan LF berada pada rentang 0.04 Hz– 0.15 Hz. Seluruh nilai *power* yang berada pada rentang frekuensi tersebut masing-masing akan dirata-rata untuk mendapatkan nilai HF dan LF. Perhitungan nilai HF dan LF dapat dilihat pada Persamaan (2) dan Persamaan (3).

$$Value_{LF} = \frac{\sum_{n=1}^n Power_{n(0.04-0.15Hz)}}{Jumlah\ frekuensi_{0.04-0.15Hz}} \quad (2)$$

$$Value_{HF} = \frac{\sum_{n=1}^n Power_{n(0.15-0.4Hz)}}{Jumlah\ frekuensi_{0.15-0.4Hz}} \quad (3)$$

### 2.5 Klasifikasi Naïve Bayes

Klasifikasi *Naïve Bayes* digunakan untuk mendapatkan hasil kondisi seseorang, yaitu berupa Normal, menderita OSA, atau CSA. Perhitungan ini

didasarkan oleh teorema *Bayes*, namun tiap fitur yang didapatkan dari objek untuk klasifikasi bersifat independen, tidak bergantung antara fitur satu dengan fitur lainnya. Rumus yang digunakan untuk metode klasifikasi ini dapat dilihat pada Persamaan (4).

$$P(A|B) = P(A) \prod_{i=1}^n P(B_i|A) \quad (4)$$

Dimana,

A	=	Kelas
B	=	Data Uji
$P(A B)$	=	<i>Posterior probability</i> , merupakan peluang B terhadap A
$P(B A)$	=	<i>Likelihood</i> , merupakan peluang A pada seluruh B
$P(A)$	=	<i>Prior</i> , merupakan peluang A dari seluruh data

Karena prediktor yang digunakan bersifat numerik, digunakan *Gaussian Distribution* untuk menentukan probabilitas dari fitur pada sebuah kelas (Azizah, et al., 2019). Rumus *Gaussian Distribution* dapat dilihat pada Persamaan (5), dimana terdapat 2 parameter yaitu mean atau rata-rata ( $\mu$ ) dari tiap fitur pada data latih dan varian ( $\sigma^2$ ) sampel pada data latih.

$$P(B|A) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (5)$$

Rumus untuk mencari  $\mu$  dapat dilihat pada Persamaan (6).

$$\mu = \frac{\sum_{n=1}^n x_i}{N} \quad (6)$$

Dimana,

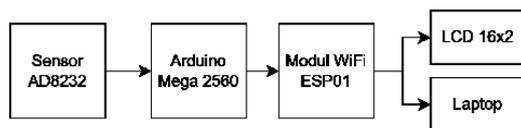
$\bar{x}$	=	Nilai rata-rata
$x_i$	=	Nilai dari sampel ke-i
n	=	Jumlah data

Digunakan standar deviasi ( $\sigma$ ) dalam menentukan nilai dari varian ( $\sigma^2$ ). Rumus standar deviasi dituliskan pada Persamaan (7).

$$\sigma = \sqrt{\frac{\sum(x_i - \mu)^2}{n-1}} \quad (7)$$

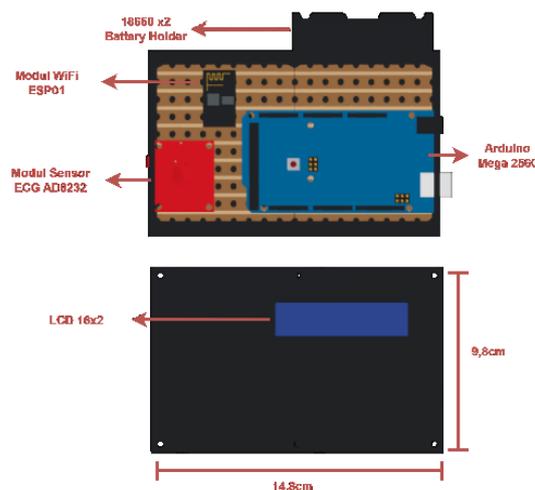
### 3. PERANCANGAN DAN IMPLENTASI SISTEM

Sistem deteksi ini dibuat untuk dapat melakukan deteksi dini apakah seseorang mengalami *Sleep-disordered Breathing* yang meliputi OSA dan CSA atau tidak. Sistem ini menggunakan sinyal ECG yang diakuisisi oleh sensor AD8232. Sinyal kemudian akan diproses oleh Arduino Mega berupa ekstraksi fitur dan juga klasifikasi menggunakan metode *Naïve Bayes*. Sebelum diekstraksi, sinyal domain waktu akan terlebih dahulu diubah ke domain frekuensi menggunakan *Fast Fourier Transform* (FFT). Hasil klasifikasi kemudian akan ditampilkan pada LCD dan dikirim menggunakan modul WiFi ESP01 ke *server* melalui jaringan yang sama untuk disimpan pada *database* dan ditampilkan pada *website*. Hasil yang ditampilkan pada *website* kemudian dapat diunduh sebagai acuan dokter untuk melakukan evaluasi lebih lanjut. Diagram blok dari sistem yang dibuat dapat dilihat pada Gambar 2.



Gambar 2. Diagram Blok Sistem

Sensor AD8232, modul WiFi ESP01, dan LCD 16x2 I2C akan dihubungkan pada Arduino Mega yang mendapat sumber daya dari baterai. Perancangan perangkat keras dalam bentuk skematik dari sistem yang dibuat dapat dilihat pada Gambar 3 dan implementasinya pada Gambar 4.

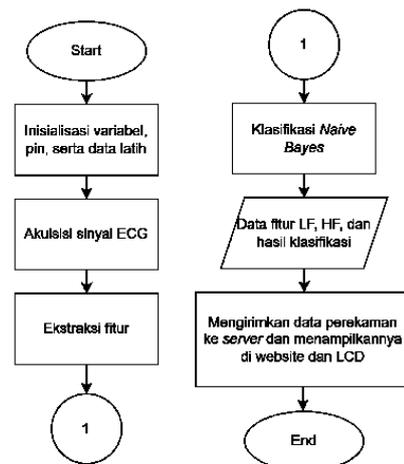


Gambar 3. Perancangan Perangkat Keras Sistem

Perancangan perangkat lunak utama meliputi proses akuisisi sinyal ECG, ekstraksi fitur, klasifikasi *Naïve Bayes*, dan penampilan serta pengiriman data dari Arduino ke *server* seperti yang ditampilkan pada Gambar 5.



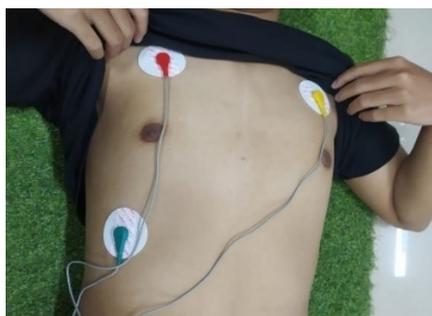
Gambar 4. Implementasi Perangkat Keras Sistem



Gambar 5. Perancangan Lunak Keseluruhan Sistem

Sebelum memulai proses akuisisi sinyal, sistem akan melakukan inisialisasi terhadap variabel yang akan digunakan. Setelah itu, sinyal ECG yang berupa sinyal analog berdomain waktu akan diakuisisi melalui sensor AD8232 dan diekstrak fiturnya. Proses ekstraksi fitur dilakukan pada sinyal yang berada diantara 2 puncak siklus ECG. Fitur yang akan digunakan adalah fitur pada domain frekuensi, sehingga akan dilakukan FFT terlebih dahulu untuk merubah sinyal dari domain waktu ke domain frekuensi. Setiap kali ekstraksi fitur dilakukan, akan didapatkan lebih dari 1 nilai HF dan LF sehingga nilai HF dan LF masing-masing akan dirata-rata untuk mendapatkan nilai parameter klasifikasi. Fitur yang telah didapatkan berupa nilai HF dan LF akan digunakan untuk melakukan klasifikasi menggunakan metode *Naïve Bayes* ke dalam kelas Normal, OSA, atau CSA. Data fitur dan hasil klasifikasi akan dikirimkan ke *server* melalui jaringan yang sama dan ditampilkan pada *website* sesuai dengan yang ditampilkan pada LCD.

Selain perancangan dan implementasi perangkat keras, perancangan penempatan elektroda juga dilakukan pada penelitian ini dengan menggunakan teknik *3-lead ECG placement*, dimana elektroda akan ditempelkan di bawah tulang selangka dalam rangka tulang rusuk kanan dan kiri, serta perut bagian bawah kanan atau kiri di bawah otot dada sebagai referensi. Implementasi penempatan elektroda pada penelitian ini ditampilkan pada Gambar 6.



Gambar 6. Implementasi Penempatan Elektroda

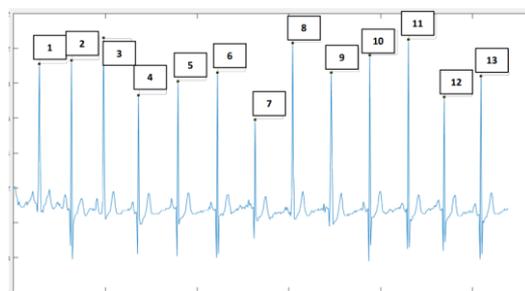
#### 4. HASIL DAN PEMBAHASAN

Hasil didapatkan dari 5 pengujian yang telah dilakukan, yaitu pengujian sensor AD8232, pengujian ketepatan pembacaan titik puncak sinyal, pengujian klasifikasi SDB menggunakan metode *Naïve Bayes*, pengujian waktu komputasi klasifikasi, dan pengujian terhadap kesesuaian tampilan *website* dan LCD. Hasil pengujian terhadap sensor AD8232 dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pengujian Sensor

Pengujian ke-	BPM Manual	BPM Sensor	Error (%)
1	79	72	9.72%
2	74	70	5.71%
3	81	83	2.41%
4	74	75	1.33%
5	79	78	1.28%
6	74	76	2.63%
7	75	72	4.17%
8	70	74	5.41%
9	76	75	1.33%
10	76	75	1.33%
<b>Rata-rata error</b>			<b>3.53%</b>

Sistem menghitung detak jantung berdasarkan titik puncak tiap siklus yang terbaca oleh sistem selama 1 menit. Hasil pembacaan sinyal ECG dengan titik puncak yang terbaca oleh sistem pada 10 detik pertama pengukuran dapat dilihat pada Gambar 7.

Gambar 7. Hasil *plot* pembacaan BPM 10 detik pertama

Hasil menunjukkan bahwa dari pengujian sebanyak 10 kali yang dilakukan dengan membandingkan detak jantung atau *Bit Per Minute* (BPM) yang terhitung oleh sistem dengan perhitungan manual, sensor mendapatkan akurasi yang sangat baik yaitu 96,47%. *Error* sebesar 3,53% dari perhitungan sistem dan perhitungan secara manual terjadi karena pengukuran secara manual

dirasa sedikit rancu dalam perhitungan *stopwatch*nya. Terkadang jantung berdenyut disaat yang sama ketika *stopwatch* baru dimulai dan terkadang juga jantung baru berdenyut beberapa saat setelah *stopwatch* dimulai.

Sinyal yang diakuisisi secara langsung pada penelitian ini adalah yang berasal dari subjek normal, sedangkan untuk subjek OSA dan CSA diakuisisi dari basis data *online*. Oleh karena itu, untuk memastikan sistem juga dapat memproses sinyal yang didapatkan dari basis data *online* dilakukan pengujian terhadap ketepatan pembacaan gelombang R atau titik puncak. Hasil pengujian ketepatan pembacaan titik puncak oleh sistem dapat dilihat pada Tabel 3.

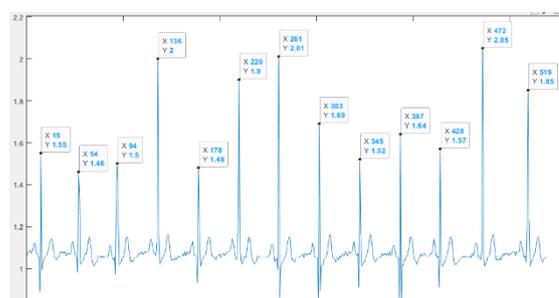
Tabel 3. Hasil Pengujian Ketepatan Pembacaan Titik Puncak

Hasil Pembacaan	Jumlah
Sesuai	63
Tidak sesuai	0
<b>Akurasi</b>	<b>100%</b>

Pengujian ini dilakukan dengan membandingkan nilai titik puncak yang terbaca dari hasil *plot* Matlab dengan nilai titik puncak yang terbaca oleh sistem. Dari 5 pengujian yang dilakukan selama masing-masing 10 detik, seluruh nilai yang terbaca dari Matlab sesuai dengan yang terbaca oleh sistem, oleh karena itu pada pengujian ini didapatkan akurasi sebesar 100%. Nilai hasil pembacaan titik puncak oleh Matlab dan sistem masing-masing dapat dilihat pada Gambar 8 dan Gambar 9.

```
Sinyal ECG : 1.12
Sinyal ECG : 1.07
Sinyal ECG : 1.05
Sinyal ECG : 1.05
Sinyal ECG : 1.04
Sinyal ECG : 1.08
Sinyal ECG : 2.05
Sinyal ECG : 1.06
Nilai Tertinggi System : 2.05
Sinyal ECG : 1.01
Sinyal ECG : 1.02
Sinyal ECG : 1.03
Sinyal ECG : 1.05
Sinyal ECG : 1.06
```

Gambar 8. Amplitudo Sinyal Jantung pada Serial Monitor Arduino IDE

Gambar 9. Sinyal Hasil *Plot* Matlab

Selanjutnya adalah pengujian klasifikasi *Naïve Bayes* untuk mengetahui performa metode ini dalam melakukan klasifikasi *Sleep-disordered Breathing* ke dalam 3 kelas, yaitu Normal, OSA, dan CSA berdasarkan parameter HF dan LF. Pengujian ini dilakukan terhadap 20 data uji dari 14 subjek

pengujian. Hasil pengujian klasifikasi *Naïve Bayes* dapat dilihat pada Tabel 4.

Tabel 4. Hasil Pengujian Klasifikasi

Keterangan	Kelas		
	Normal	OSA	CSA
Prediksi sesuai	9	4	4
Prediksi salah	1	1	1
<b>Total</b>			<b>20</b>
<b>Akurasi</b>			<b>85%</b>

Dari 20 data pengujian, terdapat 3 data yang hasil klasifikasinya masih belum sesuai, sehingga didapatkan akurasi sebesar 85%.

Ketiga adalah pengujian terhadap waktu komputasi klasifikasi. Pengujian waktu komputasi dari klasifikasi *Naïve Bayes* dilakukan untuk mengetahui berapa waktu yang dibutuhkan sistem dalam melakukan klasifikasi dari tiap input yang diberikan. Hasil pengujian waktu komputasi dapat dilihat pada Tabel 5.

Tabel 5. Hasil Pengujian Waktu Komputasi

Pengujian ke-	Waktu Komputasi (ms)
1	12
2	12
3	12
4	12
5	11
6	13
7	12
8	12
9	12
10	12
<b>Rata-rata</b>	<b>12</b>

Dari 10 pengujian yang dilakukan, didapatkan rata-rata waktu komputasi sebesar 12ms, dimana angka ini terbilang sangat cepat sehingga dapat mendukung sistem yang akan dibuat untuk melakukan diagnosis dini gangguan tidur SDB.

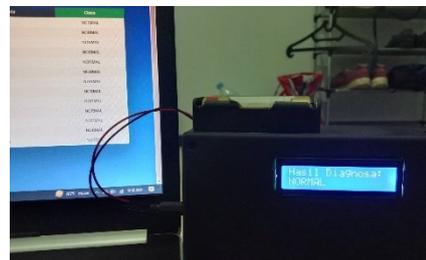
Pengujian terakhir dilakukan untuk mengetahui kemampuan modul WiFi ESP01 dalam mengirimkan data ke *localhost database* melalui jaringan yang sama dan kesesuaian tampilan data pada LCD dan *website* yang dapat diunduh dalam bentuk file berekstensi .pdf. Hasil pengujian ini dapat dilihat pada Tabel 6.

Tabel 6. Hasil Kesesuaian Tampilan *Website* dengan LCD

Pengujian ke-	Kesesuaian	
	Sesuai	Tidak Sesuai
1	✓	
2	✓	
3	✓	
4	✓	
5	✓	
6	✓	
7	✓	
8	✓	
9	✓	
10	✓	

Dari 10 pengujian yang dilakukan, data perekaman serta hasil klasifikasi seluruhnya dapat

terkirim dan ditampilkan pada *website* sesuai dengan yang ditampilkan pada LCD dengan sempurna. Tampilan kesesuaian hasil klasifikasi pada *website* dan LCD dapat dilihat pada Gambar 10.



Gambar 10. Tampilan *Website* dan LCD

Selain itu, data pada *website* yang terlihat pada Gambar 11 juga dapat diunduh dalam bentuk file .pdf yang dapat dilihat pada Gambar 12.

Timestamp	Low Frequency	High Frequency	Class
2023-12-12 09:07:51	1.85	1.04	NORMAL
2023-12-12 09:08:01	1.78	1.23	NORMAL
2023-12-12 09:08:12	1.37	1.08	NORMAL
2023-12-12 09:08:22	1.4	1.19	NORMAL
2023-12-12 09:08:32	1.36	1.12	NORMAL
2023-12-12 09:08:43	1.21	0.96	NORMAL
2023-12-12 09:08:53	1.21	1.01	NORMAL
2023-12-12 09:09:04	1.92	1.26	NORMAL
2023-12-12 09:09:14	1.84	1.11	NORMAL
2023-12-12 09:09:25	1.03	0.99	NORMAL
2023-12-12 09:09:37	2.22	1.66	NORMAL
2023-12-12 09:10:24	1.23	1.13	NORMAL
2023-12-12 09:10:35	1.1	1.22	NORMAL
2023-12-12 09:10:45	1.64	1.29	NORMAL
2023-12-12 09:10:55	1.14	1.02	NORMAL
2023-12-12 09:11:06	1.38	1.42	NORMAL
2023-12-12 09:11:17	0.95	0.82	NORMAL
2023-12-12 09:11:27	1.23	1.1	NORMAL

Gambar 11. Tampilan Data pada *Website*

Patient Sleep Record			
Timestamp	Low Frequency	High Frequency	Class
2023-12-12 09:07:51	1.85	1.04	NORMAL
2023-12-12 09:08:01	1.78	1.23	NORMAL
2023-12-12 09:08:12	1.37	1.08	NORMAL
2023-12-12 09:08:22	1.4	1.19	NORMAL
2023-12-12 09:08:32	1.36	1.12	NORMAL
2023-12-12 09:08:43	1.21	0.96	NORMAL
2023-12-12 09:08:53	1.21	1.01	NORMAL
2023-12-12 09:09:04	1.92	1.26	NORMAL
2023-12-12 09:09:14	1.84	1.11	NORMAL
2023-12-12 09:09:25	1.03	0.99	NORMAL
2023-12-12 09:09:37	2.22	1.66	NORMAL
2023-12-12 09:10:24	1.23	1.13	NORMAL
2023-12-12 09:10:35	1.1	1.22	NORMAL
2023-12-12 09:10:45	1.64	1.29	NORMAL
2023-12-12 09:10:55	1.14	1.02	NORMAL
2023-12-12 09:11:06	1.38	1.42	NORMAL
2023-12-12 09:11:17	0.95	0.82	NORMAL
2023-12-12 09:11:27	1.23	1.1	NORMAL

Gambar 12. Isi File Hasil Perekaman

Tampilan isi file berbentuk catatan berisi *timestamp*, data fitur, serta hasil klasifikasi yang akan digunakan untuk dokter melakukan evaluasi lebih lanjut terhadap pasien

### 5. KESIMPULAN

Berdasarkan pengujian yang telah dilakukan, diperoleh kesimpulan bahwa sensor AD8232 mampu mengakuisisi sinyal jantung atau ECG dengan akurasi sebesar 96,47% melalui perbandingan perhitungan BPM secara manual dan melalui sistem. Performa klasifikasi *Naïve Bayes* menunjukkan hasil yang sangat baik dari 20 pengujian, yaitu akurasi sebesar 85% dengan rata-rata waktu komputasi 12ms. Data berupa fitur dan hasil klasifikasi juga dapat terkirimkan dengan sempurna ke *server*

menggunakan modul WiFi ESP01 dan ditampilkan di *website* sesuai dengan yang ditampilkan pada LCD.

#### DAFTAR PUSTAKA

- ABIDIN, R.J., Kaffah, F.M., Khaerunisa, P., Dauni, P. and Saputra, M.I.N., 2019. Sleep disorder diagnosis expert system using certainty factor method. *Journal of Physics: Conference Series*.
- AZIZAH, N., Goejantoro, R. and Sifriyani, 2019. Prosiding Seminar Nasional Matematika, Statistika, dan Aplikasinya.
- BENJAFIELD, A. V., AYAS, N.T., ,dkk., 2019. Estimation of the global prevalence and burden of obstructive sleep apnoea: a literature-based analysis. *The Lancet Respiratory Medicine*, 7(8), pp.687–698.
- GRANDNER, M.A., 2017. Sleep, Health, and Society. *Sleep Medicine Clinics*.
- HUNG, P.D., 2018. Detection of central sleep apnea based on a single-lead ECG. *ACM International Conference Proceeding Series*. Association for Computing Machinery. pp.78–83.
- KOZA, I., MAULANA, R. & FITRIYAH, H., 2021. Implementasi Sistem Pendeteksi Obstructive Sleep Apnea berdasarkan Parameter Interval QT dan Interval PR menggunakan Metode Naïve Bayes.
- QUEENS HEALTH, 2018. 7 amazing things that happen to your body while you sleep | Queensland Health. Tersedia di: <<https://www.health.qld.gov.au/news-events/news/7-amazing-things-that-happen-to-your-body-while-you-sleep>> [Diakses 7 Agustus 2022].
- SATEIA, M.J., 2014. International classification of sleep disorders-third edition highlights and modifications. *Chest*, 146(5), pp.1387–1394.
- SIMONELLI, G., dkk., 2018. Sleep health epidemiology in low and middle-income countries: A systematic review, and meta-analysis of the prevalence of poor sleep quality and sleep duration.
- SZOLLOSI, I., dkk., 2007. Sleep Apnea in Heart Failure Increases Heart Rate Variability and Sympathetic Dominance. 30(*Sleep*).
- WELLS, M.E., 2018. Evolving Relationship Between Sleep-Disordered Breathing and Stroke - American College of Cardiology. Tersedia di: <<https://www.acc.org/latest-in-cardiology/articles/2015/06/25/08/24/evolving-relationship-between-sleep-disordered-breathing-and-stroke>> [Diakses 7 Agustus 2022].

*Halaman ini sengaja dikosongkan*