

Gated Recurrent Units dalam Mendeteksi Obstructive Sleep Apnea

JASMAN PARDEDE, MUHAMMAD FAUZAN RASPATI

Program Studi Informatika, Institut Teknologi Nasional Bandung
Email: jasman@itenas.ac.id

Received 4 Agustus 2021 | Revised 16 November 2021 | Accepted 30 November 2021

ABSTRAK

Dalam melakukan penelitian obstructive sleep apnea (OSA), polysomnography (PSG) digunakan untuk diagnosis. Namun subjek diharuskan menginap dilaboratorium selama beberapa malam untuk melakukan tes dengan PSG dan karena banyaknya alat yang harus dikenakan pada tubuh dapat membuat tidak nyaman saat pengambilan data. Belakangan ini, beberapa peneliti menggunakan single-lead ECG untuk melakukan deteksi OSA. Untuk menghasilkan model terbaik, akan dilakukan eksperimen training, dengan batch normalization dan dropout yang berbeda. Pada penelitian ini apnea-ecg dataset digunakan, RR-Interval dan amplitudo QRS complex dari released set berjumlah 35 data akan disegmentasi permenit untuk digunakan sebagai input dari arsitektur yang diajukan adalah gated recurrent unit (GRU). Lalu withheld set berjumlah 35 data akan digunakan untuk pengujian per-segment dan per-recording. Kinerja sistem diukur berdasarkan accuracy, sensitivity, dan specificity dengan pengujian per-segment mendapat hasil accuracy 83.92%, sensitivity 81.28%, dan specificity 85.55%, dan pengujian per-recording mendapat hasil accuracy 97.14%, sensitivity 95.65% dan specificity 100%.

Kata kunci: *Obstructive sleep apnea, GRU, ECG, RR-Interval, QRS complex.*

ABSTRACT

In conducting obstructive sleep apnea (OSA) studies, polysomnography (PSG) was used for the diagnosis. However, the subject was required to stay in the laboratory for several nights to carry out tests with the PSG and because of the many devices that had to be worn on the body, it could be uncomfortable to collect data. Recently, several researchers have used single-lead ECG to detect OSA. To produce the best model, training experiments will be conducted, with different batch normalization and dropout. In this study, the apnea-ecg dataset is used, the RR-Interval and the QRS complex amplitude from the released set totaling 35 data will be segmented per minute to be used as input for the proposed architecture is the gated recurrent unit (GRU). Then the withheld set of 35 data will be used for per-segment and per-recording testing. System performance was measured based on accuracy, sensitivity, and specificity with per-segment testing getting 83.92% accuracy, 81.28% sensitivity, and 85.55% specificity, and per-recording testing got 97.14% accuracy, 95.65% sensitivity and 100% specificity.

Keywords: *Obstructive sleep apnea, GRU, ECG, RR-Interval, QRS complex.*

1. PENDAHULUAN

Salah satu gangguan tidur yang paling sering ditemukan adalah *sleep apnea* (henti nafas pada waktu tidur). Beberapa gejala dari *sleep apnea* berupa rasa tercekik ketika tidur, nafas terengah-engah, mengantuk dipagi hari, hilangnya konsentrasi, dan gejala yang paling sering timbul pada *sleep apnea* adalah mendengkur. Mendengkur (*snoring*) adalah suara bising yang disebabkan oleh aliran udara melalui sumbatan saluran nafas pada bagian belakang hidung dan mulut yang terjadi saat tidur. *Sleep apnea* ditandai dengan kolaps berulang dari saluran nafas atas (**Darmadi, Rizal, Sunarya, 2015**). Pada 35-45% pria dan 15-28% wanita memiliki kebiasaan mendengkur. Akan tetapi, tidak semua orang yang mempunyai kebiasaan mendengkur menderita OSA (**Purwowiyoto, 2018**). Pengaruh buruk dari mendengkur dapat mengakibatkan dampak yang serius seperti peningkatan risiko terjadinya tekanan darah tinggi, serangan jantung, stroke, depresi berat, sulit konsentrasi, frustasi, dan sering marah. Kualitas tidur yang tidak baik disebabkan oleh mendengkur juga dapat menyebabkan seseorang menjadi sering mengantuk saat beraktivitas.

Untuk melakukan sebuah diagnosis OSA, dilakukan *full night polysomnography* (PSG) pada laboratorium tidur (**Wang, 2019**). PSG melakukan rekaman minimal sebelas sinyal fisiologis yang dikumpulkan dari berbagai sensor, beberapa diantaranya adalah *electrocardiogram* (ECG), *electromyogram* (EMG), *electroencephalogram* (EEG), *electrooculography* (EOG), dan sinyal pernafasan (**Song, 2016**). Dimana sensor ini digunakan pada tubuh yang akan melakukan diagnosis OSA, sehingga membuat sedikit tidak nyaman saat hendak tidur. Ukuran keparahan dari OSA dapat dilihat dari AHI (*apnea-hypopnea index*), kriteria AHI berdasarkan standar adalah AHI < 5 diindikasikan sebagai kondisi normal, AHI 15 – 30 sebagai kategori ringan, AHI > 30 diindikasikan sebagai kategori berat (**Hudgel, 2016**).

Beberapa penelitian mengenai OSA dengan menggunakan *dataset apnea-ecg* dari physionet sebelumnya pernah dilakukan. Pada tahun 2015 Carolina Varon (**Varon, 2015**) melakukan penelitian *single-lead* ECG yang disegmentasi permenit untuk deteksi *sleep apnea* menggunakan dua fitur yang berasal dari sinyal ECG yaitu *QRS complex* dan RR-interval (RRI), klasifikasi menggunakan LS-SVM. Pada tahun 2016 Changyue Song (**Song, 2016**) melakukan penelitian single-lead ECG dengan 2 ekstrasi fitur yaitu RRI dan sinyal EDR dan data disegmentasi permenit, proses klasifikasi menggunakan metode HMM-SVM. Tao Wang (**Wang, 2019**) pada 2019 melakukan penelitian OSA dengan fitur otomatis dari RRI dan amplitude, dalam melakukan klasifikasinya menggunakan arsitektur LeNet-5. Lalu pada tahun 2021 Haifa Almutairi (**Almutairi, Hassan, Datta, 2021**) melakukan penelitian OSA menggunakan ekstrasi fitur dari RRI dan *QRS amplitude*, *k-fold cross validation* digunakan untuk data dan CNN-LSTM digunakan untuk klasifikasi.

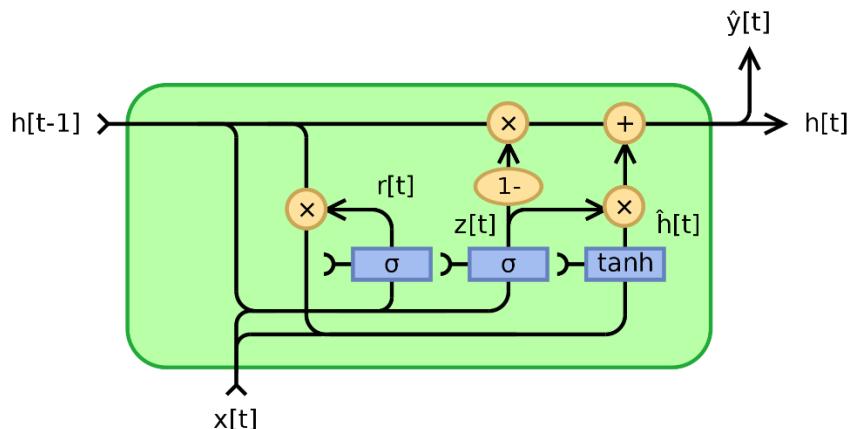
Pada penelitian ini, akan melakukan deteksi OSA menggunakan sinyal ECG yang akan dilakukan *preprocessing* dengan melakukan ekstrasi fitur frekuensi domain dari RRI dan *amplitude QRS complex*, proses klasifikasi menggunakan *recurrent neural network* dengan arsitektur *gated recurrent unit* (GRU), dan untuk mengukur kinerja sistem akan menggunakan *confusion-matrix*, dengan menghitung *accuracy*, *sensitivity*, dan *specificity*. *Dataset* yang digunakan dalam penelitian ini berasal dari Dr. Thomas Penzel dari Phillips-University, Marburg, Jerman.

2. METODE PENELITIAN

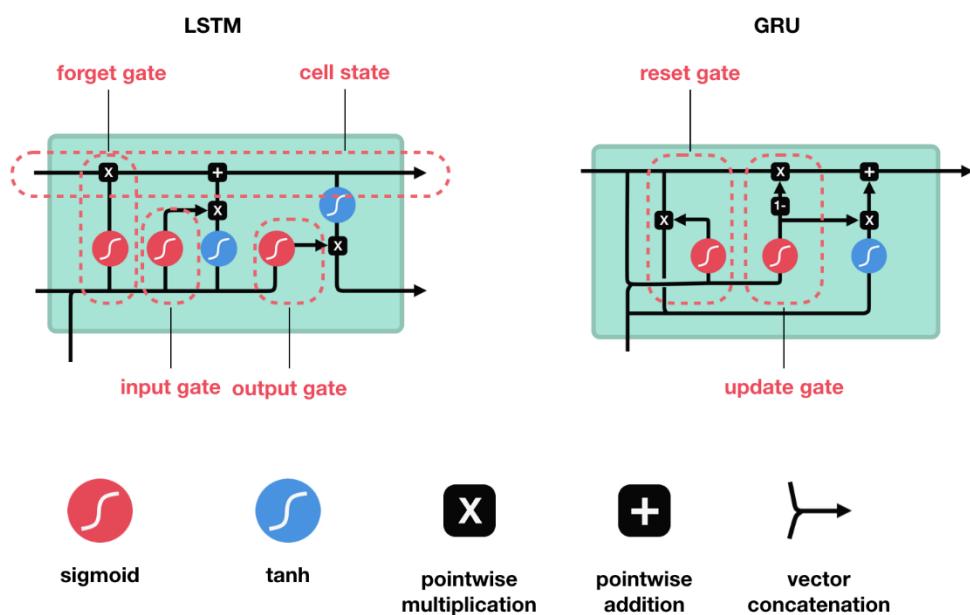
Pada penelitian ini, masukan untuk sistem berupa data sinyal ECG dengan format *.dat*, *.apn*, dan *.qrs* yang didapatkan dari Physionet. Data ini akan melalui tahapan *pre-processing*, *training*, dan *testing*.

2.1. Gated Recurrent Unit

Gated recurrent unit merupakan salah satu varian dari *recurrent neural network* yang dibuat untuk membuat setiap *recurrent unit* dapat menangkap *dependencies* dengan skala waktu yang berbeda – beda secara *adaptive* (**Chung, 2014**), dan juga untuk mengatasi masalah *vanishing gradient* (**Shen, 2018**). Gambar 1 merupakan arsitektur dari GRU.



Gambar 1. Arsitektur Gated Recurrent Unit



Gambar 2. Arsitektur LSTM(Kiri) dan GRU(Kanan)

GRU merupakan variasi yang lebih sederhana dari varian lainnya, yaitu *long short term memory* (LSTM). Gambar 2 merupakan ilustrasi dari arsitektur GRU dan LSTM. GRU merupakan salah satu arsitektur yang didesain untuk mengatasi masalah data sekuens atau *time-series* (**Le, 2019**). GRU memiliki tiga gerbang dalam melakukan komputasi yaitu *update gate* pada Persamaan 1 untuk membantu model menentukan berapa banyak informasi yang perlu dilanjutkan ke tahap selanjutnya, *reset gate* pada Persamaan 2 untuk memutuskan berapa banyak informasi sebelumnya yang akan dilupakan, *current memory content* pada Persamaan 3 dimana akan menggunakan *reset gate* untuk menyimpan informasi yang relevan dari masa lalu, dan *final memory* pada Persamaan 4 yang

menggunakan *update gate* untuk menyimpan informasi untuk unit saat ini dan informasi dari langkah sebelumnya untuk diteruskan ke jaringan selanjutnya.

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (1)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (2)$$

$$\tilde{h} = \tanh(W_h x_t + r_h * U_h h_{t-1} + b_h) \quad (3)$$

$$h_t = z_t * h_{(t-1)} + (1 - z_t) * \tilde{h} \quad (4)$$

Keterangan:

z = *Update gate*

Tanh = Fungsi aktivasi tanh

r = *Reset gate*

W = Bobot

\tilde{h} = *Current memory content*

x_t = Input

h = *Final memory*

U = *hidden state*

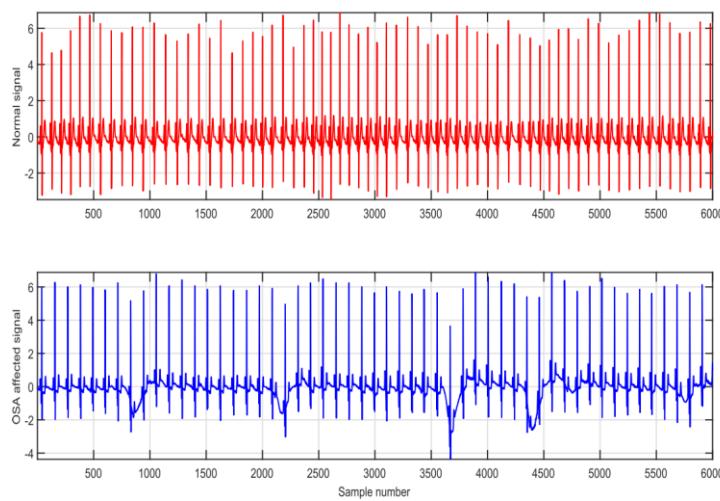
σ = Fungsi aktivasi sigmoid

b = *Bias vector*

Untuk mekanisme dari gerbang GRU dimana z , r , \tilde{h} , dan h adalah *update gate*, *reset gate*, *current memory content*, dan *final memory*. Untuk σ dan tanh merepresentasikan fungsi aktivasi yang digunakan pada GRU. x_t merupakan input ke layer pada waktu t . Dan untuk W , U , dan b merupakan bobot, *hidden state*, dan *bias vector*.

2.2. Dataset

Pada penelitian ini, *dataset* yang digunakan adalah *apnea-ecg* dari physionet. Terdapat 70 rekaman ECG pada *dataset* ini dengan durasi yang bervariasi, mulai dari 401 menit hingga 578 menit (**Penzel, 2000**). Rekaman ini memiliki resolusi 16-bit dan rekaman diambil sampelnya pada 100 Hz. Rekaman ini dilakukan segmentasi 1 menit dan diberi label "normal" (N) dan "apnea" (A) oleh ahlinya (**Li, 2018**). Rekaman ECG ini terdiri dari 2 set dimana masing – masingnya berisi 35 rekaman. Set pertama (*released set*) digunakan untuk membangun model dan memvalidasi model dan set kedua (*withheld set*) digunakan untuk menguji model.



Gambar 3. Normal(atas) dan Apnea(bawah)

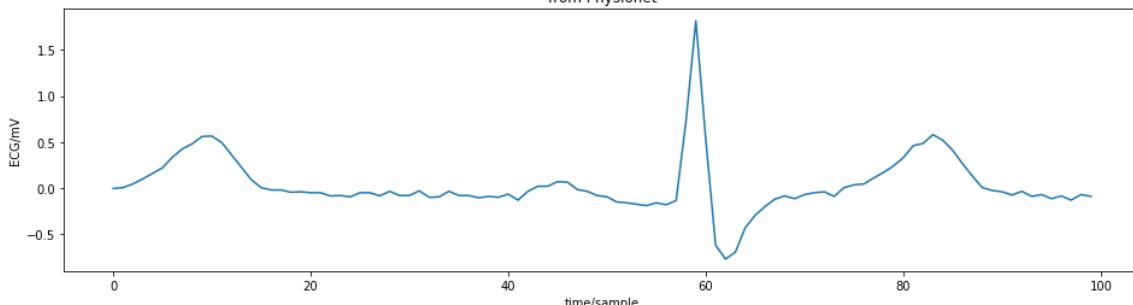
Terdapat beberapa file yang saling terhubung pada setiap rekaman, .hea merupakan informasi mengenai nama dan format dari rekaman, .apn berisi anotasi untuk setiap menit

dari rekaman yang menunjukkan ada atau tidaknya apnea pada setiap menitnya, .qrs berisi anotasi QRS complex pada sinyal ECG, dan .dat berisi ECG sinyal. Karena durasi rekaman ECG yang bervariasi, membuat kelas yang terdapat pada *dataset* ini memiliki jumlah yang berbeda. Sehingga *dataset* yang ini menjadi *imbalance*, dimana jumlah salah satu kelas lebih banyak daripada kelas yang lainnya (**Kulkarni, Chong, Batarseh, 2020**). Berikut merupakan cuplikan dan visualisasi salah satu rekaman ECG dengan ekstensi .dat dari *dataset* yang digunakan.

Time	ECG(mV)	Time	ECG(mV)	Time	ECG(mV)	Time	ECG(mV)
0:00.000	-0.005	0:00.280	-0.035	0:00.560	-0.180	0:00.840	0.520
0:00.010	0.005	0:00.290	-0.080	0:00.570	-0.135	0:00.850	0.410
0:00.020	0.045	0:00.300	-0.080	0:00.580	0.725	0:00.860	0.265
0:00.030	0.100	0:00.310	-0.030	0:00.590	1.815	0:00.870	0.130
0:00.040	0.160	0:00.320	-0.100	0:00.600	0.530	0:00.880	0.005
0:00.050	0.220	0:00.330	-0.095	0:00.610	-0.620	0:00.890	-0.025
0:00.060	0.335	0:00.340	-0.035	0:00.620	-0.770	0:00.900	-0.040
0:00.070	0.425	0:00.350	-0.080	0:00.630	-0.695	0:00.910	-0.075
0:00.080	0.480	0:00.360	-0.080	0:00.640	-0.430	0:00.920	-0.035
0:00.090	0.560	0:00.370	-0.105	0:00.650	-0.295	0:00.930	-0.090
0:00.100	0.565	0:00.380	-0.090	0:00.660	-0.200	0:00.940	-0.070
0:00.110	0.495	0:00.390	-0.100	0:00.670	-0.120	0:00.950	-0.115
0:00.120	0.360	0:00.400	-0.065	0:00.680	-0.085	0:00.960	-0.085
0:00.130	0.225	0:00.410	-0.130	0:00.690	-0.115	0:00.970	-0.130
0:00.140	0.090	0:00.420	-0.035	0:00.700	-0.070	0:00.980	-0.070
0:00.150	0.005	0:00.430	0.020	0:00.710	-0.050	0:00.990	-0.090
0:00.160	-0.020	0:00.440	0.020	0:00.720	-0.040		
0:00.170	-0.020	0:00.450	0.070	0:00.730	-0.090		
0:00.180	-0.045	0:00.460	0.065	0:00.740	0.005		
0:00.190	-0.040	0:00.470	-0.015	0:00.750	0.035		
0:00.200	-0.050	0:00.480	-0.035	0:00.760	0.045		
0:00.210	-0.050	0:00.490	-0.080	0:00.770	0.110		
0:00.220	-0.085	0:00.500	-0.095	0:00.780	0.170		
0:00.230	-0.080	0:00.510	-0.150	0:00.790	0.240		
0:00.240	-0.095	0:00.520	-0.160	0:00.800	0.330		
0:00.250	-0.050	0:00.530	-0.175	0:00.810	0.460		
0:00.260	-0.050	0:00.540	-0.190	0:00.820	0.485		
0:00.270	-0.085	0:00.550	-0.160	0:00.830	0.580		

Gambar 4. Cuplikan Data Selama 1 Detik

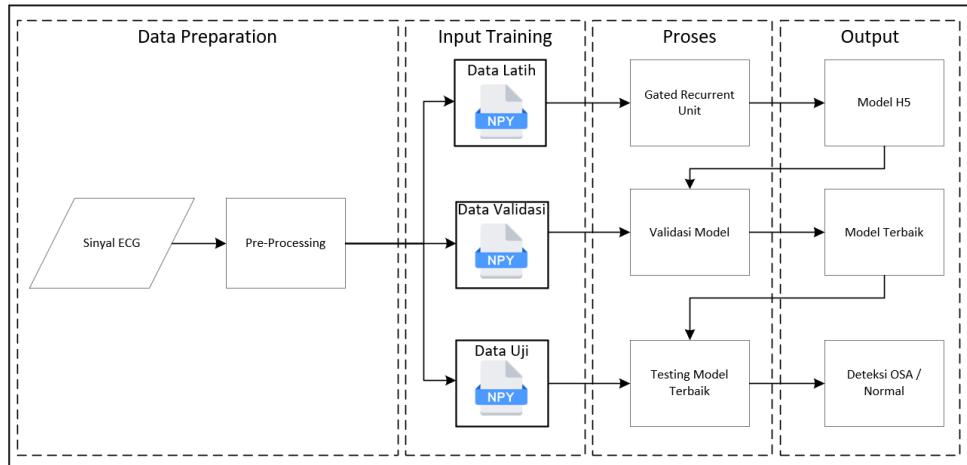
from Physionet



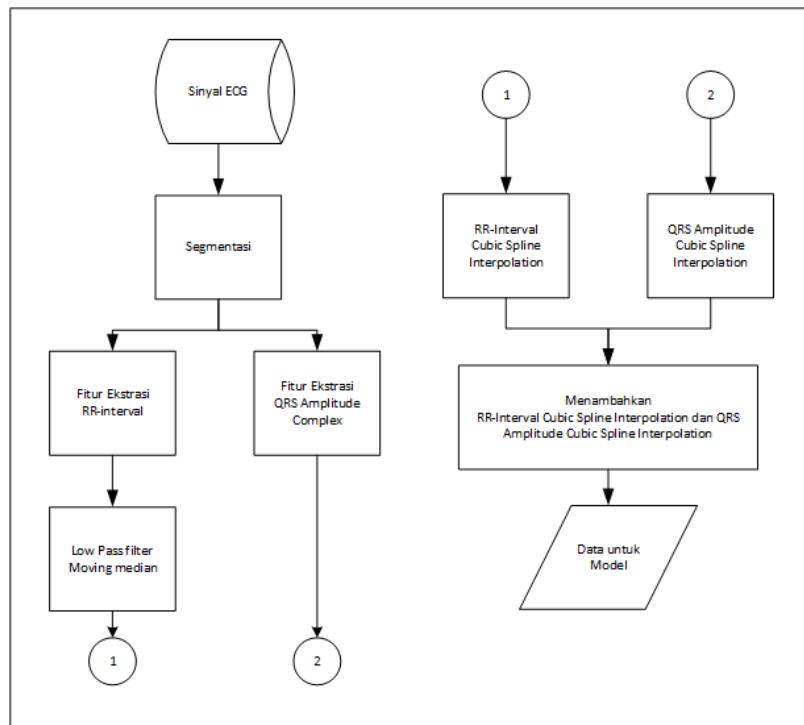
Gambar 5. Visualisasi data selama 1 detik

2.3. Perancangan Sistem

Bagian ini memaparkan proses perancangan sistem deteksi *obstructive sleep apnea* dengan metode *gated recurrent unit*. Gambar 6 merupakan blok diagram secara keseluruhan.



Gambar 6. Blok Diagram Sistem

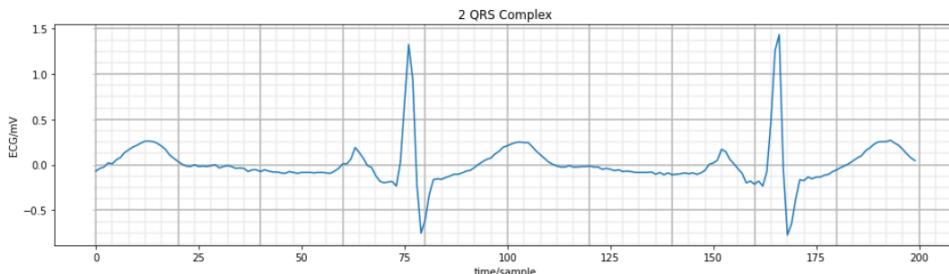


Gambar 7. Blok Diagram Pre-Processing

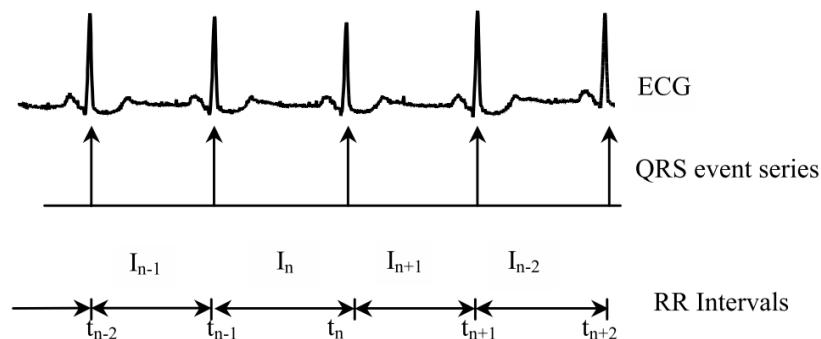
Released set yang berjumlah 35 rekaman ECG disegmentasi menjadi 16461 menit, untuk *withheld set* yang berjumlah 35 rekaman ECG akan disegmentasi menjadi 16732 menit. *Released set* yang sudah disegmentasi akan dibagi menjadi 80% data latih dan 20% data validasi, dan untuk data tes akan menggunakan *withheld set* dengan 2 macam pengujian. Kemudian setiap data akan dilakukan *pre-processing* untuk mendapatkan nilai – nilai yang dibutuhkan. Sebelum melakukan deteksi OSA, akan dilakukan pelatihan menggunakan metode GRU dengan data latih dan data validasi, keluaran hasil pelatihan ini menghasilkan model dengan format .h5, dengan data validasi yang akan mengukur kinerja model hingga menghasilkan model terbaik yang akan digunakan untuk testing. Data tes yang sudah disiapkan dan melalui tahap *pre-processing* akan digunakan untuk testing terhadap model terbaik yang dihasilkan, hingga *output* dari data tes ini adalah deteksi OSA.

2.4. Pre-Processing

Tahapan *pre-processing* pada Gambar 8, akan mengekstraksi interval waktu antara detak jantung secara berturut – turut untuk mendapatkan *RR-Interval*. Proses ekstrasi yang pertama adalah mendapatkan nilai *RR-interval*. *RR-interval* adalah jarak dari 2 *QRS complex* ($\text{QRS}[n] - \text{QRS}[1-n]$), dan domain waktu dari *RR-interval* adalah titik tengah dari *QRS complex*.

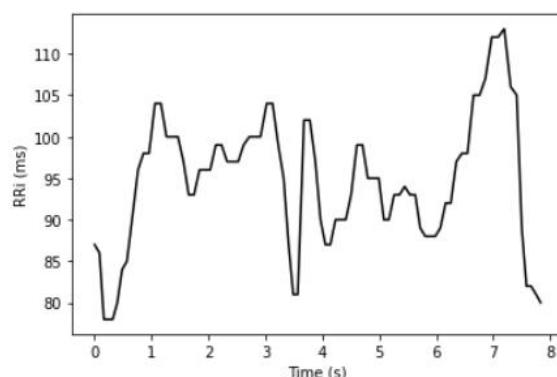


Gambar 8. QRS Complex pada Sinyal ECG



Gambar 9. Ilustrasi ECG dengan QRS dan RR Interval (Singh, Vinod, Saxena 2004)

Untuk beberapa kasus, nilai *RR-interval* akan muncul dengan nilai yang tidak diinginkan sehingga akan menimbulkan hasil yang tidak sempurna, maka akan dilakukan *low-pass filter* untuk menghilangkan derau menggunakan *moving median*. *RR-interval* yang sudah didapatkan akan dilakukan *cubic spline interpolation* untuk menghilangkan interval palsu (**Almutairi et al., 2021**).



Gambar 10. Plot RR-interval dari Domain Waktu

Setelah dilakukan *cubic spline interpolation*, nilai akan dilakukan *batchnormalization* yang berguna untuk mempercepat proses training dan meningkatkan *learning rates* pada saat pembuatan model. *Batchnormalization* berkerja dengan menyamakan distribusi pada setiap

nilai input yang selalu berubah – ubah dikarenakan perubahan parameter pada layer sebelumnya selama proses *training* (**Ioffe, Szegedy, 2016**).

2.5. Training

Proses ini merupakan pembuatan model dengan arsitektur GRU. Data latih dan data validasi akan melalui tahapan ini, dimana akan melakukan *training* menggunakan metode GRU dengan parameter seperti pada Tabel 1.

Tabel 1. Parameter Model

Epoch	Optimizer	Learning rate	Dropout
100	Adam	0.0005	0.1
			0.2
			0.3
			0.4
			0.5

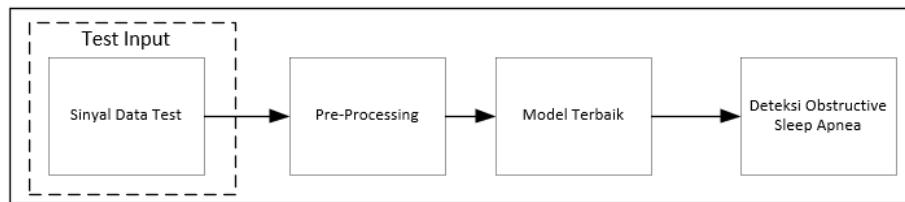
Pada penelitian ini terdapat beberapa parameter yang digunakan, *epoch* digunakan sebagai penanda berapa kali model melakukan perulangan pada data latih secara keseluruhan. Optimizer yang digunakan pada pembuatan model ini adalah adam. Adam pertama kali dipresentasikan pada ICLR 2015 oleh Diederik P.Kingma dan Jimmi Lei Ba (**Kingma, Ba, 2015**). Pada beberapa penelitian, optimizer adam memiliki hasil yang baik dibandingkan dengan optimizer lainnya (**Brownlee, 2017**). Dalam mengatasi perbedaan jumlah class dari apnea dan normal, regularisasi *dropout* dijadikan eksperimen dalam menghasilkan model terbaik, karena *dropout* merupakan salah satu cara untuk menghindari *overfitting* (**Srivastava, 1993**).

2.6. Testing

Pada tahap ini akan dilakukan 2 macam pengujian, dengan melakukan pengujian per-*segment* dan per-*recording*. Pengujian per-*segment* dilakukan untuk menguji kinerja sistem secara keseluruhan karena menggunakan keseluruhan rekaman yang disegmentasi permenit dan juga memberi dasar yang kuat untuk melakukan diagnosis seseorang yang dicurigai OSA (**Wang, 2019**). Sebuah rekaman ECG terdiri dari beberapa segmentasi permenit, dan untuk klasifikasi setiap rekaman berdasarkan pada keseluruhan segmentasi permenit, maka dilakukan pengujian per-*recording* untuk melakukan deteksi OSA. AHI akan digunakan untuk membedakan mana rekaman yang OSA dan normal pada pengujian per-*recording*. Jika AHI > 5 maka akan dideteksi sebagai OSA dan jika kurang akan dideteksi sebagai normal. Karena setiap segmentasi permenit memiliki label OSA atau normal, maka perkiraan jumlah menit dengan OSA per jam dapat dihitung sebagai berikut:

$$AHI = \frac{60}{T} * jumlah\ segmentasi\ OSA \quad (5)$$

Dimana T merupakan jumlah menit segmentasi rekaman ECG, $T/60$ merupakan jumlah jam dari segmentasi rekaman ECG, lalu akan dikalikan dengan jumlah segmentasi OSA. Nilai AHI ini nantinya akan dibandingkan dengan nilai AHI yang sebenarnya dari *dataset* untuk menentukan rekaman ECG tersebut OSA atau normal. Tahapan *testing* seperti pada Gambar 11.

**Gambar 11. Tahapan Testing**

2.7. Evaluasi

Evaluasi dalam mengukur kinerja sistem ini, mengukur *accuracy*, *sensitivity*, dan *specificity* dengan *confusion matrix*. Dalam melakukan diagnosis sebuah penyakit, *sensitivity* dan *specificity* biasa digunakan untuk evaluasi kinerja sistem. *Confusion matrix* merupakan ukuran yang biasa digunakan dalam memecahkan masalah *binary classification* dan masalah *multiclass classification* (**Kulkarni, Chong, Batarseh, 2020**). *Sensitivity* merupakan persentase *true positive* dengan kondisi OSA, dan *specificity* merupakan persentase *true negative* dengan kondisi normal (**Bolin, Lam, 2013**). Tabel 2 merupakan *confusion matrix* untuk *binary classification*.

Tabel 2. Confusion Matrix

		Predicted	
		Negative	Positive
Actual	Negative	TN	FP
	Positive	FN	TP

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

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

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (8)$$

Keterangan :

- TP = Jumlah class apnea yang terprediksi apnea.
- TN = Jumlah class normal yang terprediksi normal.
- FP = Jumlah class normal yang terprediksi apnea.
- FN = Jumlah class apnea yang terprediksi normal.

Pada penelitian ini hasil dari TP merupakan “*true positive*” dimana data positif yang terprediksi benar, subjek yang OSA terprediksi memiliki OSA. Untuk FP merupakan “*false positive*” dimana data negative terprediksi sebagai data *positive*, subjek yang normal terprediksi memiliki OSA. Begitupun sebaliknya, untuk TN merupakan “*true negative*” dimana data negative yang terprediksi benar, subjek normal terprediksi normal. Untuk FN merupakan “*false negative*” dimana data *positive* terprediksi sebagai data *negative*, subjek yang OSA terprediksi normal.

3. HASIL DAN PEMBAHASAN

Penelitian ini dilakukan menggunakan produk dari *Google Research* yaitu *Google Colab (Colab)* untuk membantu proses *training*, spesifikasi yang disediakan untuk colab pro yaitu menggunakan *Graphic Processing Unit (GPU)* Tesla P100. Untuk testing menggunakan processor Intel Core i7-5500U @2.40GHz, *Random Access Memory (RAM)* 8 GB, GPU Nvidia GeForce GTX 850M. Hasil penelitian ini akan dituangkan dan dijabarkan pada bagian ini. Sistem ini dibangun menggunakan bahasa pemrograman Python 3.8 dengan menggunakan library dari *Tensorflow 2.5*, dalam mengolah sinyal ECG menggunakan *library waveform-database (WFDB)* dan *library heart rate variability (HRV)*.

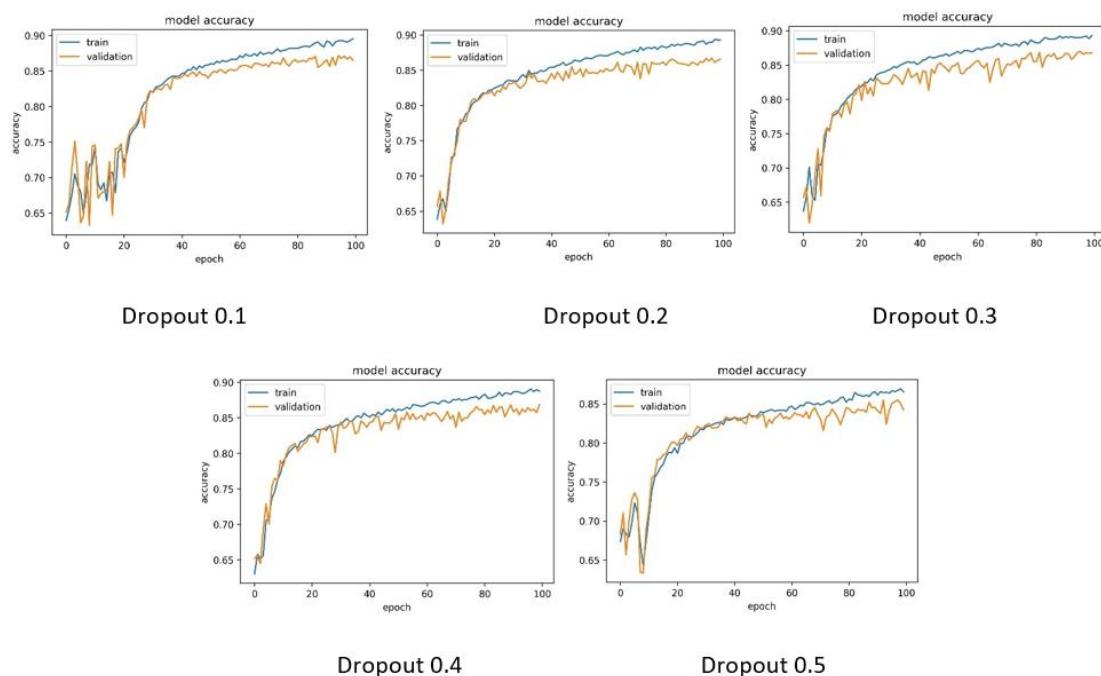
3.1. Training

Untuk mendapatkan model terbaik dari arsitektur GRU, dilakukan pelatihan model dengan menggunakan *released set* yang telah dibagi menjadi 80% data latih dan 20% data validasi. Layer yang digunakan untuk membangun model terdapat pada Tabel 3.

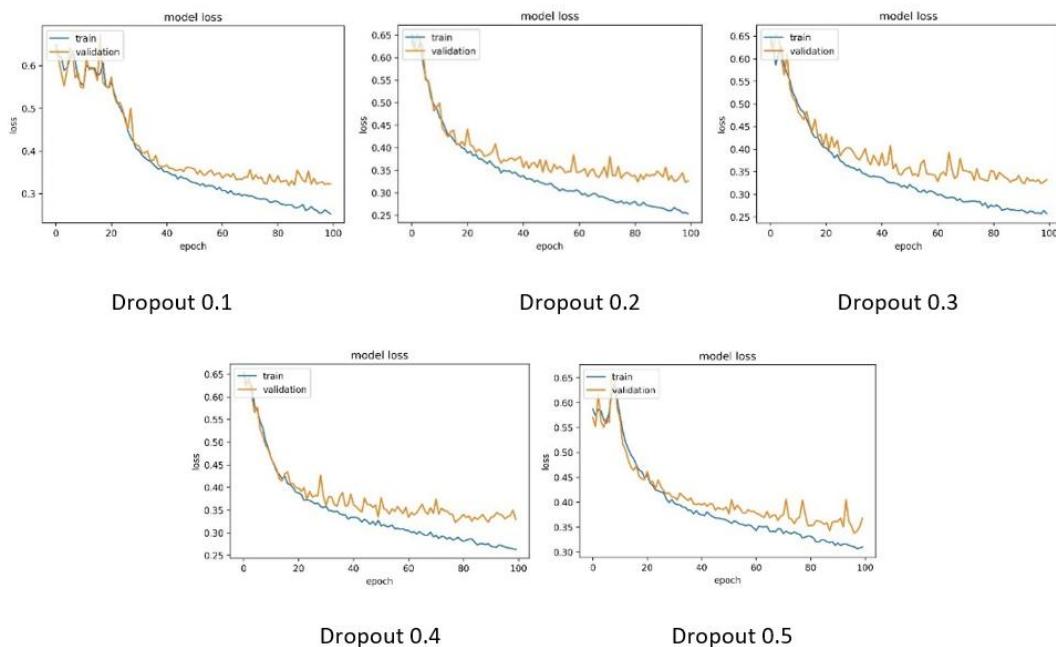
Tabel 3. Struktur Model

No	Layer	Unit
1.	Batchnormalization	-
2.	GRU	64
3.	GRU 1	128
4.	Dense	64
5.	Dense 1	1

Eksperimen dilakukan menggunakan *dropout* 0.1, 0.2, 0.3, 0.4, dan 0.5, 100 *epoch*, 128 *batch size*, *optimizer Adam*, dan *learning rate* 0.00005. Gambar 10 dan Gambar 11 merupakan hasil *accuracy* dan *loss* dari eksperimen training. Dimana sumbu x merupakan jumlah *epoch* yang digunakan dan sumbu y merupakan informasi *accuracy* dan *loss*.



Gambar 12. Accuracy untuk Dropout yang Berbeda



Gambar 13. Loss untuk Dropout yang berbeda

Dari grafik yang ditampilkan pada Gambar 10 dan Gambar 11, memperlihatkan perubahan *accuracy* dan *loss* saat proses training dengan *dropout* yang berbeda. Seluruh model akan digunakan pengujian untuk mengetahui pada *dropout* berapa yang menghasilkan model terbaik.

3.2. Pengujian

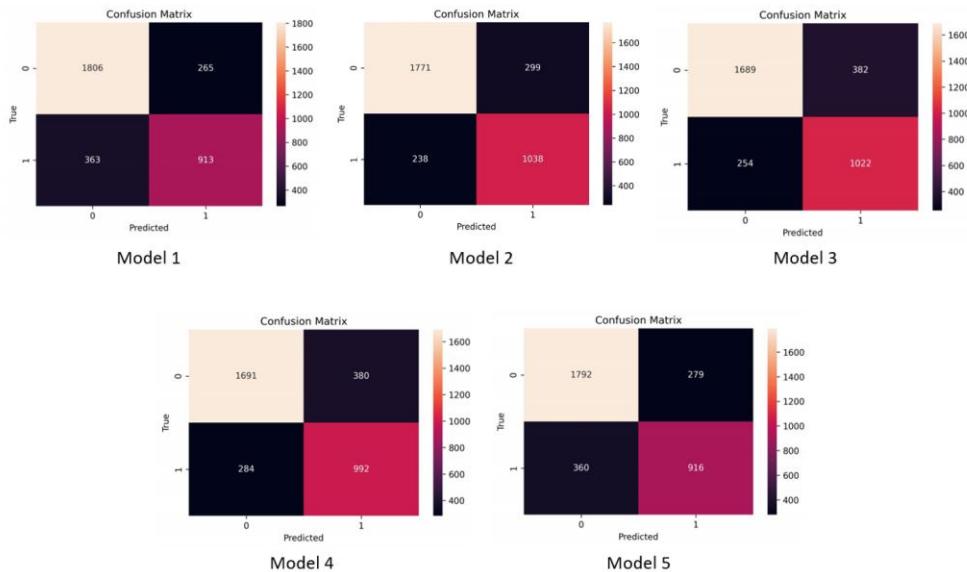
Pengujian terhadap model terbaik akan dilakukan dengan 2 cara, yaitu pengujian per-*segment* dan per-*recording*.

3.2.1. Pengujian Per-Segment

Pada pengujian per-*segment* akan menggunakan 20% data dari *withheld set* yang telah disegmentasi menjadi 16732. Sebanyak 3347 data dari *withheld set* secara acak akan digunakan untuk pengujian per-*segment*. Dengan mengukur kinerja arsitektur GRU menggunakan *confusion-matrix* dimana mengukur kinerja sistem secara keseluruhan berdasarkan *accuracy*, *sensitivity* dan *specificity* dihitung menggunakan Persamaan (6), (7), dan (8). Pada Gambar 12 merupakan hasil *confusion-matrix* dari 3347 data test yang digunakan, dan Tabel 4 merupakan perbandingan dari setiap model.

Tabel 4. Perbandingan setiap Model

Model	Accuracy	Sensitivity	Specificity
Model 1	81.23%	71.55%	87.20%
Model 2	83.92%	81.28%	85.55%
Model 3	80.99%	80.09%	81.55%
Model 4	80.16%	77.74%	81.65%
Model 5	80.90%	71.78%	86.52%



Gambar 14. Confusion-matrix Data Test pada setiap Model

Berdasarkan hasil pengujian per-*segment* dengan data tes, menunjukkan bahwa model 2 memiliki *accuracy* dan *sensitivity* yang tinggi. *Sensitivity* yang tinggi penting untuk menjadi acuan dalam deteksi sebuah penyakit, karena memiliki hasil *true positive* yang tinggi. Maka model 2 akan digunakan untuk melakukan pengujian per-recording untuk deteksi OSA.

3.2.2. Pengujian Per-Recording

Untuk mendeteksi OSA atau normal akan menggunakan *withheld set* yang berjumlah 35 rekaman (x01 – x35). Nilai AHI akan digunakan untuk diagnosis. Perbandingan nilai AHI yang tersedia dengan hasil prediksi nilai AHI terdapat pada Tabel 5.

Tabel 5. Hasil Per-Recording untuk x01-x35

Rekaman ECG	Anotasi Oleh Ahli		Model GRU	
	AHI	Deteksi	AHI oleh Sistem	Deteksi
X01	63	OSA	36.2	OSA
X02	37.7	OSA	21.7	OSA
X03	0.13	Normal	0.64	Normal
X04	0	Normal	0	Normal
X05	34	OSA	33.9	OSA
X06	0	Normal	0	Normal
X07	21	OSA	24.6	OSA
X08	48	OSA	33.9	OSA
X09	18.5	OSA	14.7	OSA
X10	10	OSA	7.20	OSA
X11	5	Normal	0.92	Normal
X12	33	OSA	4.91	Normal

Rekaman ECG	Anotasi Oleh Ahli		Model GRU	
	AHI	Deteksi	AHI oleh Sistem	Deteksi
X13	18.7	OSA	21.9	OSA
X14	79.5	OSA	37.7	OSA
X15	15.9	OSA	12	OSA
X16	24	OSA	6.54	OSA
X17	0	Normal	0.17	Normal
X18	0	Normal	0	Normal
X19	56.2	OSA	47.5	OSA
X20	43	OSA	25.3	OSA
X21	19	OSA	12.8	OSA
X22	0	Normal	0	Normal
X23	14.3	OSA	12	OSA
X24	0	Normal	0	Normal
X25	48	OSA	32.8	OSA
X26	15.1	OSA	27.4	OSA
X27	75	OSA	53.5	OSA
X28	75	OSA	46.1	OSA
X29	0	Normal	0	Normal
X30	41	OSA	34.5	OSA
X31	93.5	OSA	37.6	OSA
X32	71.8	OSA	31.3	OSA
X33	0.13	Normal	0.12	Normal
X34	0.38	Normal	0.25	Normal
X35	0	Normal	0	Normal

Tabel 6. Evaluasi Per-Recording

Actual	Predicted		Pengukuran
	Negative	Positive	
Negative	12	0	Sensitivity 95.65%
Positive	1	22	Specificity 100%

Dari hasil evaluasi untuk deteksi OSA per-recording mendapatkan hasil akurasi 97.14%, namun perlu diingatkan bahwa withheld set hanya memiliki 35 data, yang mengakibatkan pengujian per-segment mendapatkan hasil yang lebih rendah.

4. KESIMPULAN

Pada penelitian ini, telah mengimplementasikan arsitektur GRU untuk melakukan deteksi OSA. Model GRU pada penelitian ini menggunakan 100 *epoch*, 128 *batch size*, *optimizer* Adam, dan *learning rate* 0.0005. Dalam melakukan optimasi model, *early stopping* pada proses *training* digunakan untuk menghentikan proses pelatihan ketika akurasi validasi tidak ada peningkatan selama 20 *epoch*. Regularisasi dari *dropout* digunakan untuk membantu mengurangi *overfitting* pada model. Hasil eksperimen pada *dropout* 0.2 mendapatkan hasil pengujian per-segmentasi terbaik dengan hasil *accuracy* 83.92%, *sensitivity* 81.28%, dan *specificity* 85.55%. Untuk melakukan pengujian per-recording, 35 data dari *withheld set* digunakan untuk deteksi OSA, dengan hasil *accuracy* 97.14%, *sensitivity* 95.65% dan *specificity* 100%. Kedua pengujian yang dilakukan memperlihatkan bahwa penggunaan jumlah data dapat mempengaruhi hasil *accuracy* yang didapatkan, sehingga pengujian per-recording mendapatkan hasil yang lebih tinggi karena jumlah data yang digunakan tidak sebanyak pengujian per-segmentasi.

DAFTAR RUJUKAN

- Almutairi, H., Hassan, G. M., & Datta, A. (2021). Detection of obstructive sleep apnoea by ECG signals using deep learning architectures. *European Signal Processing Conference, 2021-Janua*, 1382–1386. <https://doi.org/10.23919/Eusipco47968.2020.9287360>
- Bolin, E., & Lam, W. (2013). A review of sensitivity, specificity, and likelihood ratios: Evaluating the utility of the electrocardiogram as a screening tool in hypertrophic cardiomyopathy. *Congenital Heart Disease*, 8(5), 406–410. <https://doi.org/10.1111/chd.12083>
- Brownlee, J. (2017). *Gentle Introduction to the Adam Optimization Algorithm for Deep Learning*. Neural Networks. <https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning/>
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. 1–9. <http://arxiv.org/abs/1412.3555>
- Darmadi, F., Rizal, A., & Sunarya, U. (2015). Deteksi Sleep Apnea Melalui Analisis Suara Dengkuran Dengan Metode Mel Frekuensi Cepstrum. 2(2), 2681–2686.
- Hudgel, D. W. (2016). Sleep Apnea Severity Classification Revisited. *Sleep*, 39(5), 1165–1166. <https://doi.org/10.5665/sleep.5776>
- Ioffe, S., & Szegedy, C. (2016). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *Journalism Practice*, 10(6), 730–743. <https://doi.org/10.1080/17512786.2015.1058180>
- Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–15.

- Kulkarni, A., Chong, D., & Batarseh, F. A. (2020). Foundations of data imbalance and solutions for a data democracy. In *Data Democracy: At the Nexus of Artificial Intelligence, Software Development, and Knowledge Engineering*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-818366-3.00005-8>
- Le, X. H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of Long Short-Term Memory (LSTM) neural network for flood forecasting. *Water (Switzerland)*, 11(7). <https://doi.org/10.3390/w11071387>
- Penzel, T., Moody, G. B., Mark, R. G., Goldberger, A. L., & Peter, J. H. (2000). Apnea-ECG database. *Computers in Cardiology*, 255–258.
- Purwowyoto, S. L. (2018). Obstructive Sleep Apnea dan Gagal Jantung. *YARSI Medical Journal*, 25(3), 172. <https://doi.org/10.33476/jky.v25i3.364>
- Shen, G., Tan, Q., Zhang, H., Zeng, P., & Xu, J. (2018). Deep learning with gated recurrent unit networks for financial sequence predictions. *Procedia Computer Science*, 131, 895–903. <https://doi.org/10.1016/j.procs.2018.04.298>
- Singh, D., Vinod, K., & Saxena, S. C. (2004). Sampling frequency of the RR interval time series for spectral analysis of heart rate variability. *Journal of Medical Engineering and Technology*, 28(6), 263–272. <https://doi.org/10.1080/03091900410001662350>
- Song, C., Liu, K., Zhang, X., Chen, L., & Xian, X. (2016). An Obstructive Sleep Apnea Detection Approach Using a Discriminative Hidden Markov Model from ECG Signals. *IEEE Transactions on Biomedical Engineering*, 63(7), 1532–1542. <https://doi.org/10.1109/TBME.2015.2498199>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (1993). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Physics Letters B*, 299(3–4), 345–350. [https://doi.org/10.1016/0370-2693\(93\)90272-J](https://doi.org/10.1016/0370-2693(93)90272-J)
- Varon, C., Caicedo, A., Testelmans, D., Buyse, B., & Van Huffel, S. (2015). A Novel Algorithm for the Automatic Detection of Sleep Apnea from Single-Lead ECG. *IEEE Transactions on Biomedical Engineering*, 62(9), 2269–2278. <https://doi.org/10.1109/TBME.2015.2422378>
- Wang, T., Lu, C., Shen, G., & Hong, F. (2019). Sleep apnea detection from a single-lead ECG signal with automatic feature-extraction through a modified LeNet-5 convolutional neural network. *PeerJ*, 2019(9), 1–17. <https://doi.org/10.7717/peerj.7731>