

Klasifikasi Obstructive Sleep Apnea (OSA) Berdasarkan Fitur Statistik Interval RR pada Sinyal ECG

Desanti Nurma Risalah¹, Yoyon K. Suprpto¹, Diah Puspito Wulandari¹

¹Dept. Teknik Komputer Institut Teknologi Sepuluh Nopember Surabaya, Indonesia

Email: desantinurma@gmail.com, yoyonsuprpto@ee.its.ac.id, diah@te.its.ac.id,

Abstrak

Obstructive sleep apnea (OSA) adalah gangguan umum di mana seseorang berhenti bernapas saat tidur yang dapat menyebabkan penyakit kardiovaskular jika tidak ditangani dengan baik. Sebagian besar kasus sleep apnea diuji menggunakan polisomnografi (PSG), yang merupakan prosedur standar untuk diagnosis semua gangguan tidur. Namun, sebagian besar kasus sleep apnea masih tidak terdiagnosis karena prosedur pengujian yang mahal dan tidak praktis, mengingat polisomnografi (PSG) dilakukan di laboratorium tidur dan memerlukan pengamat manusia ahli yang harus bekerja semalaman. Penelitian ini mengusulkan suatu metode untuk mendeteksi OSA berdasarkan sinyal ECG menggunakan klasifikasi. Sinyal ECG dapat dimanfaatkan untuk membuat sistem deteksi menjadi lebih sederhana dan lebih cepat dibandingkan PSG. Sinyal ECG diperoleh dari dataset PhysioNet menggunakan 10 subjek perekaman yang berbeda. Data direkam selama 2 malam berturut-turut menggunakan perekaman ECG satu kanal. Fitur statistik diekstraksi berdasarkan interval RR yang memproses epoch berdurasi pendek dari data ECG. Hasil ekstraksi fitur digunakan sebagai masukan klasifikasi dengan metode Support Vector Machine untuk dilatih dan diuji pada rekaman tidur dari subjek dengan dan tanpa OSA. Kinerja sistem ditentukan dengan memperoleh nilai Akurasi, Sensitivitas, dan Spesifisitas. Hasil penelitian menunjukkan bahwa sistem mampu mengenali epoch gangguan tidur dengan tingkat akurasi yang tinggi, yaitu sekitar 83,67%. Di masa depan, sistem yang dibuat diharapkan dapat dikembangkan dan digunakan sebagai dasar pengembangan alat skrining OSA.

Keyword: ECG, OSA, RR interval, Support Vector Machine

Diterima Redaksi: 04-07-2024 Selesai Revisi: 10-07-2024 Diterbitkan Online: 15-07-2024
DOI: <https://doi.org/10.59378/jcenim.v2i2.50>

I. PENDAHULUAN

Sepanjang rata-rata masa hidup, manusia tidur sekitar 7 jam per hari. Hal ini berarti manusia menghabiskan sekitar sepertiga dari hidupnya untuk tidur. Merasa tidak enak badan setelah semalaman tidak tidur merupakan cara tubuh mengingatkan kita bahwa tidur dibutuhkan seperti eating, drinking, dan breathing. Ketika kita tidur, tubuh melakukan self-improvement. Tanpa tidur, kita tidak dapat berfungsi dengan baik karena poor body condition.

Terdapat lebih dari 70 jenis sleep disorders yang telah ditemukan, termasuk yang paling umum seperti insomnia, sleep apnea, narcolepsy, dan restless leg syndrome [1]. Gejala sleep disorder yang paling umum di masyarakat adalah snoring. Banyak orang meremehkan snoring. Namun, snoring dapat menjadi gejala serius dari respiratory illness saat tidur, seperti apnea.

Gejala apnea tidak hanya terjadi pada malam hari tetapi juga pada siang hari, sebagaimana sleep disorders pada umumnya [2]. Apnea membuat patients merasa tired continuously. Pada siang hari, excessive sleepiness, concentration disorders, depression, dan bahkan memory loss merupakan hal yang umum terjadi [3]. Gejala-gejala ini terjadi karena people with sleep disorders tidak mendapatkan quality sleep pada malam hari.

Menurut American Thoracic Society, beberapa cardiovascular conditions dapat terjadi akibat untreated OSA. Patients with OSA cenderung memiliki high blood pressure (hypertension). Hypertension tersebut kemudian memicu heart attacks, strokes, dan arrhythmia [2]. Selain itu, repeated respiratory distress menyebabkan heart mengalami stress, yang mengarah pada heart enlargement [4].

Secara umum, apnea testing biasanya menggunakan polysomnography (PSG), yang merupakan standard procedure untuk diagnosis semua sleep disorders. PSG merekam airflow, respiratory movement,

oxygen saturation, body position, electroencephalogram (EEG), electrooculogram (EOG), electromyogram (EMG), dan electrocardiogram (ECG) [5]. Sebagian besar kasus apnea masih undiagnosed karena inconvenience of testing, high cost of testing, dan limited testing availability [6]. PSG testing mahal karena hanya dilakukan di special laboratories di hospitals dan memerlukan machines, doctors, technicians, dan staff untuk bekerja all night. Testing ini uncomfortable karena patients harus stay overnight di testing room selama examination. Selain itu, PSG testing availability terbatas karena existing test chambers selalu penuh, dan patients yang register harus menunggu dalam waiting list selama months.

Sebagai rangkuman, dependency on PSG untuk diagnosis perlu ditangani dengan mengembangkan simpler detection methods dan faster treatment options. Saat ini, lebih banyak techniques terkait biometry sedang diteliti dan dikembangkan untuk health diagnostics, termasuk electrocardiogram (ECG).

II. KAJIAN PUSTAKA

Beberapa metode telah diusulkan untuk identifikasi sleep apnea dalam beberapa tahun terakhir. Statistical features dari berbagai sinyal seperti nasal airflow, thorax and abdomen effort signals, acoustic speech signals, oxygen saturation, electrical activity of the brain (EEG), dan electrical activity of the heart (ECG) umum digunakan dalam proses detection.

Ng et al. [7] menunjukkan bahwa thoracic dan abdominal signals merupakan parameter yang baik untuk mengidentifikasi terjadinya sleep apnea. Dengan menggunakan mean of absolute amplitudes dari thoracic dan abdominal signals, mereka mencapai performa yang baik dengan nilai receiver operating characteristic lebih tinggi dari 80%.

Berdasarkan hipotesis bahwa speech signal properties dari pasien OSA berbeda dengan mereka yang tidak memiliki OSA, Goldshtein et al. [8] mengembangkan sistem berbasis Gaussian mixture model untuk melakukan klasifikasi antara kelompok OSA dan non-OSA. Mereka mencapai specificity dan sensitivity sebesar 83% dan 79% untuk pasien OSA pria serta 86% dan 84% untuk pasien OSA wanita. Teknik yang digunakan bergantung pada vocal tract length dan linear prediction coefficient features.

Penelitian oleh Alvarez et al. [9] mengevaluasi comprehensive feature set berbasis blood oxygen saturation (SaO_2) dari nocturnal oximetry untuk menilai sleep quality. Tiga fitur dari sinyal SaO_2 —delta index, central tendency measure, dan oxygen desaturation index—dievaluasi. Akurasi central tendency measure lebih tinggi dibandingkan delta index dan oxygen desaturation index. Dengan menggunakan central tendency measure, sensitivity yang diperoleh adalah 90.1% dan specificity sebesar 82.9%.

Hubungan antara periodic changes pada profil oxygen saturation (SaO_2) dan EEG patterns akibat apnea events selama malam hari diteliti oleh Alvarez et al. [10]. Spectral analysis dari kedua sinyal tersebut mencapai sensitivity sebesar 91%, specificity sebesar 83.3%, dan accuracy sebesar 88.5% dalam diagnosis OSA.

Dalam penelitian oleh Xie dan Minn [11], berbagai feature sets dan kombinasi classifiers berbasis arterial oxygen saturation yang diukur menggunakan pulse oximetry (SpO_2) dan ECG dianalisis untuk mengevaluasi sleep quality dan mendeteksi apnea. Dengan selected features dari sinyal SpO_2 dan ECG, classifier Bagging dengan REP Tree mencapai sensitivity sebesar 79.75%, specificity sebesar 85.89%, dan overall accuracy sebesar 84.40%.


Wavelet transforms dan artificial neural network (ANN) algorithms diterapkan pada sinyal EEG dalam penelitian oleh Lin et al. [12] untuk mengidentifikasi sleep apnea (SA) episodes. Hasil identifikasi sistem mencapai sensitivity sekitar 69.64% dan specificity sekitar 44.44%.

Banyak penelitian menunjukkan bahwa detection dari obstructive sleep apnea dapat dilakukan melalui heart rate variability (HRV) dan sinyal ECG. Quiceno-Manrique et al. [13] mengusulkan diagnostic tool sederhana untuk OSA dengan accuracy yang tinggi (hingga 92.67%) menggunakan time-frequency distributions dan dynamic features pada sinyal ECG.

Berdasarkan spectral components dari heart rate variability, frequency analysis dilakukan dalam penelitian oleh Schader et al. [14] menggunakan Fourier dan Wavelet Transformation dengan penerapan Hilbert Transform yang sesuai, di mana sensitivity yang diperoleh adalah 90.8%. Selain itu, Mendez et al. [15] menggunakan bivariate autoregressive model untuk mengevaluasi beat-by-beat power spectral density dari HRV dan R peak area, di mana hasil classification menunjukkan accuracy lebih tinggi dari 85%. Teknik ini juga bergantung pada ECG signal features. Almazaydeh [6] juga menggunakan RR interval features dari sinyal ECG.

III. DESAIN DAN IMPLEMENTASI

Penelitian ini berfokus pada feature extraction dari sinyal ECG untuk OSA detection. Block diagram dari penelitian ini dapat dilihat pada Gambar 1.



Gambar 1: Block diagram

A. Subjek

Database sinyal ECG yang digunakan tersedia dari situs PhysioNet. PhysioNet berisi koleksi sinyal biomedis yang terus berkembang dari subjek sehat dan pasien. Situs PhysioNet merupakan layanan publik dari PhysioNet Resource yang didanai oleh National Institutes of Health melalui NIBIB dan NIGMS. PhysioNet menyediakan akses gratis ke Apnea-ECG Database, yang digunakan untuk menilai dan memvalidasi pendekatan yang diusulkan. ApneaECG Database berisi 70 rekaman, masing-masing berisi satu sinyal ECG dengan durasi yang bervariasi dari sedikit kurang dari 7 jam hingga hampir 10 jam. Sampling frequency yang digunakan untuk akuisisi ECG adalah 100 Hz, dengan resolusi 16-bit, dan satu sample bit merepresentasikan 5 μ V. Posisi elektroda ECG standar laboratorium tidur digunakan (modified lead V2) [5].

Subjek dari rekaman ini terdiri dari pria dan wanita berusia antara 27 hingga 63 tahun (mean: 43.8 ± 10.8 tahun) dengan berat badan antara 53 hingga 135 kg (mean: 86.3 ± 22.2 kg). Rekaman tidur berasal dari 32 subjek (25 pria, 7 wanita) yang direkrut untuk penelitian sebelumnya pada healthy volunteers dan pasien dengan obstructive sleep apnea [5].

B. Electrocardiogram (ECG)


Electrocardiogram, yang disebut sebagai ECG, merupakan representasi dari electrical activity jantung yang direkam oleh elektroda yang ditempatkan pada permukaan tubuh. Satu sinyal ECG yang utuh terdiri dari beberapa rhythm atau beat. Setiap beat mengandung P waves, QRS complexes, dan T waves. Setiap peak (P, Q, R, S, T, dan U), intervals (PR, RR, QRS, ST, dan QT), serta segments (PR dan ST) dari sinyal ECG memiliki nilai amplitudo atau durasi normal. Peak, interval, dan segment ini disebut sebagai ECG features. Representasi skematik dari ECG normal ditunjukkan pada Gambar 2.

ECG dianggap sebagai salah satu fitur yang paling efisien untuk mendeteksi sleep disorders [6]. Cyclic variations pada durasi heartbeats, yang juga dikenal sebagai RR intervals (interval waktu dari satu R wave ke R wave berikutnya) dari ECG, telah dilaporkan berhubungan dengan sleep apnea episodes [6]. Bradycardia terjadi selama apnea yang diikuti oleh tachycardia saat apnea berakhir [5]. Menurut Almazaydeh et al. [6], RR interval time series dihasilkan untuk setiap ECG beat, seperti yang ditunjukkan pada Persamaan 1:

$$RR_i = RR_{i+1} - RR_i, \quad i = 1, 2, \dots, n - 1 \quad (1)$$

dengan:

- RR_i = RR interval pada iterasi ke- i
- i = index iterasi
- n = jumlah data



Gambar 2: Normal cycle of ECG signal

C. Pemrosesan Mula

Pre-processing terdiri dari tiga tahap, yaitu data selection, segmentation, dan RR interval detection untuk data apnea dan non-apnea.

Seleksi Data

Sinyal dengan durasi total 7–10 jam kemudian dipilih dengan 10 menit kondisi apnea dan 10 menit kondisi non-apnea. Sebagai contoh, pada record a03, data dari 3:10:00.000 hingga 3:20:00.000 dipilih sebagai data apnea, dan untuk data regular, pemilihan dilakukan dari 2:28:00.000 hingga 2:38:00.000.

Pada record b03, data dari 2:44:00.000 hingga 2:54:00.000 dipilih sebagai data apnea, dan untuk data regular, pemilihan dilakukan dari 00:07:00.000 hingga 00:17:00.000. Data yang dipilih dari suatu periode tertentu ditentukan dengan mempertimbangkan beberapa aspek, yaitu sinyal pada periode tersebut bersih (noise-free), wave features jelas dan tidak bercampur (tidak terdapat campuran apnea dan non-apnea dalam satu periode pemilihan), serta data berada dalam jam yang sama. Dalam penelitian ini, digunakan 12 record yang berbeda dari subjek yang berbeda.

Python programming digunakan dalam eksperimen untuk signal processing. Data records diimpor dalam format Comma Separated Values (.csv) dari situs PhysioNet.

Segmentasi

Tahap selanjutnya adalah segmentasi data. Dalam penelitian ini, lima kasus segmentation dianalisis:


- Data apnea dan regular disegmentasi menjadi potongan berdurasi 10 detik.
- Data apnea dan regular disegmentasi menjadi potongan berdurasi 15 detik.
- Data apnea dan regular disegmentasi menjadi potongan berdurasi 20 detik.
- Data apnea dan regular disegmentasi menjadi potongan berdurasi 25 detik.
- Data apnea dan regular disegmentasi menjadi potongan berdurasi 30 detik.

Karena apnea didefinisikan sebagai jeda pernapasan yang dapat berlangsung dari beberapa detik hingga menit (umumnya ≥ 10 detik), lima kasus ini dianalisis untuk menentukan akurasi terbaik yang dapat dicapai.

Deteksi RR Interval

Data hasil segmentasi kemudian dianalisis untuk mendeteksi keberadaan R waves yang direpresentasikan sebagai peaks. R waves harus dibedakan dari gelombang sinyal ECG lainnya. Oleh karena itu, dua kondisi dikembangkan agar R peak detection dapat dilakukan dengan benar:

1. Harus merupakan local maximum, yang dideteksi oleh local maximum function dalam window 30 ms.
2. Local maximum peaks harus setidaknya 3.5 standard deviations di atas mean.



Gambar 3: R peak detection

D. Ekstraksi Fitur

Menurut Isa et al. [16], ECG features berikut merupakan yang paling efektif untuk apnea detection:

- Mean epoch dan recording RR-interval.
- Standard deviation dari epoch dan recording.
- NN50 measure (variant 1), didefinisikan sebagai jumlah pasangan RR-interval berurutan di mana RR-interval pertama melebihi RR-interval kedua lebih dari 50 ms.
- NN50 measure (variant 2), didefinisikan sebagai jumlah pasangan RR-interval berurutan di mana RR-interval kedua melebihi RR-interval pertama lebih dari 50 ms.
- Dua pNN50 measures, didefinisikan sebagai setiap NN50 measure dibagi dengan total jumlah RR-interval.
- SDD measures, didefinisikan sebagai standard deviation dari selisih antara RR-interval berurutan.
- RMSSD measures, didefinisikan sebagai akar kuadrat dari mean kuadrat selisih antara RR-interval berurutan.
- Median dari RR-interval.
- Interquartile range, didefinisikan sebagai selisih antara persentil ke-75 dan ke-25 dari distribusi nilai RR-interval.
- Mean absolute deviation values, didefinisikan sebagai mean dari nilai absolut yang diperoleh dengan mengurangkan mean RR-interval dalam suatu epoch.

Nilai data yang diperoleh dari feature extraction dikumpulkan dalam sebuah file. File ini berfungsi sebagai database atau kumpulan data yang kemudian diproses untuk classification process. Dalam proses ini, seluruh nilai disimpan dalam file dalam bentuk yang akan dipanggil kembali selama classification process.


E. Klasifikasi

Support Vector Machines (SVMs) digunakan dalam penelitian ini sebagai classification method untuk menyelidiki apneaic epoch detection.


Konsep SVM bertujuan untuk menemukan hyperplane terbaik sebagai pemisah dua kelas dalam input space. Permasalahan dapat didefinisikan oleh primary effort (hyperplane) yang memisahkan dua kelompok. Upaya untuk menemukan hyperplane tersebut merupakan inti dari learning process pada SVM [17].

Dalam SVM, sebuah data point P diklasifikasikan ke dalam kelas tertentu oleh hyperplane berdimensi $(P - 1)$, yang disebut sebagai linear classifier. Hyperplane optimal yang memisahkan cluster vektor ditemukan melalui SVM modeling. Kasus dengan satu kategori target variable berada di satu sisi bidang, sedangkan kasus dengan kategori lainnya berada di sisi yang lain [18].

Separator atau hyperplane terbaik antara dua kelas dapat ditemukan dengan mengukur margins hyperplane dan mencari titik maksimum. Margin adalah jarak antara hyperplane dan data terdekat dari masing-masing kelas. Data yang berada pada batas ini disebut sebagai support vector. Secara umum, semakin besar margin, semakin kecil generalization error dari classifier [16]. Fig. 4 menggambarkan cara kerja SVM algorithm, dan Fig. 5 menunjukkan trade off margin choice.



Gambar 4: SVM algorithm



Gambar 5: Trade off margin choice

SVMs menangani pemisahan melalui kernel function untuk memetakan data ke dalam space yang berbeda dengan hyperplane. SVM memberikan fleksibilitas dalam pemilihan kernel. Linear, polynomial, dan radial basis functions dapat digunakan sebagai kernel functions [6].

Pada tahap ini, 80% data digunakan untuk training dan 20% untuk testing dari total data yang tersedia untuk setiap kelompok apnea dan non-apnea. Classification dilakukan menggunakan Support

Vector Machines (SVM), yang juga dikenal sebagai supervised learning, untuk menguji apnea detection pada periode tertentu. Kernel yang digunakan terdiri dari empat kasus:

- Linear kernel
- Radial Basis Function (RBF) kernel
- Polynomial of degree 3 kernel
- Sigmoid kernel


Data training dan testing dipisahkan sebelum classification. Data testing yang digunakan tidak digunakan dalam training untuk menghindari overfitting. Overfitting merupakan salah satu permasalahan yang paling umum dalam machine learning, di mana classifier kehilangan kemampuan generalisasi sehingga menghasilkan prediksi kelas yang tidak akurat [17]. Oleh karena itu, data yang termasuk dalam training set tidak digunakan kembali pada classification testing. Classification dilakukan menggunakan fungsi SVM pada library `sklearn` dalam Python. Keempat kasus ini dianalisis bersama dengan segmentation case terbaik untuk menentukan akurasi terbaik yang dapat dicapai.

IV. HASIL

Efektivitas model dievaluasi pada Apnea ECG database menggunakan berbagai record yang tersedia dalam database tersebut. Model diimplementasikan menggunakan Python programming. Untuk mengevaluasi performa classification system, dua indikator statistik—Sensitivity (Se) dan Specificity (Sp)—digunakan selain Accuracy (Acc). Sensitivity dari suatu pengujian adalah persentase pasien dalam kelompok OSA-positive yang terdiagnosis dengan benar, sedangkan specificity adalah persentase subjek dalam kelompok OSA-negative yang diklasifikasikan dengan benar oleh pengujian tersebut.

Sensitivity dan Specificity merupakan dua nilai yang saling berlawanan. Hal ini berarti bahwa jika nilai Sensitivity meningkat, maka nilai Specificity akan menurun, dan sebaliknya.

Dalam penelitian ini, rasio data training dan testing adalah 80:20 persen. Karena data testing mencakup 20% dari seluruh data, setiap single test dilakukan sebanyak 5 kali dengan data yang berbeda untuk memperoleh average accuracy. Metode pengujian ini divisualisasikan pada Gambar 6 untuk memudahkan pemahaman.



Gambar 6: Visualisasi teknik pengujian

Experiment	Accuracy	Sensitivity	Specificity
1	73.73%	60.42%	83.33%
2	68.64%	45.83%	68.75%
3	74.43%	43.75%	97.91%
4	72.34%	47.08%	93.55%
5	80.23%	85.42%	66.25%
Average	73.87%	56.50%	81.96%

Tabel 1: Tingkat keberhasilan klasifikasi pada epoch 10 detik

Experiment	Accuracy	Sensitivity	Specificity
1	80%	76.67%	83.33%
2	88.33%	90%	86.67%
3	83.33%	76.67%	86.67%
4	80%	73.33%	86.67%
5	86.67%	80%	93.33%
Average	83.67%	79.33%	87.33%

Tabel 2: Tingkat keberhasilan klasifikasi pada epoch 15 detik

Experiment	Accuracy	Sensitivity	Specificity
1	85.00%	83.07%	86.92%
2	78.56%	84.33%	72.39%
3	81.15%	76.15%	96.15%
4	77.80%	55.01%	100.00%
5	81.69%	88.21%	55.13%
Average	80.84%	77.35%	82.12%

Tabel 3: Tingkat keberhasilan klasifikasi pada epoch 20 detik

Experiment	Accuracy	Sensitivity	Specificity
1	87.08%	89.16%	85.00%
2	82.50%	86.67%	78.33%
3	75.41%	40.00%	95.83%
4	75.83%	50.83%	95.83%
5	69.58%	80.83%	11.33%
Average	78%	69.50%	73.26%

Tabel 4: Tingkat keberhasilan klasifikasi pada epoch 25 detik

Experiment	Accuracy	Sensitivity	Specificity
1	81.00%	73.73%	73.73%
2	90.00%	68.64%	68.64%
3	80.33%	71.43%	71.43%
4	70.00%	62.34%	62.34%
5	76.33%	70.23%	70.23%
Average	79.5%	69.27%	69.27%

Tabel 5: Tingkat keberhasilan klasifikasi pada epoch 30 detik

Berdasarkan Tabel 2, SVM dengan 15-second epoch menunjukkan classification accuracy terbaik dengan tingkat keberhasilan prediksi yang tinggi, mencapai Accuracy sebesar 83.67%, Sensitivity sebesar 79.33%, dan Specificity sebesar 87.33%.

Selain variasi epoch, SVM kernel yang memberikan accuracy rate classification terbaik untuk model

juga dievaluasi. Tabel-tabel berikut menunjukkan success rate untuk empat kasus kernel. Pada tahap ini, 15-second epoch digunakan karena menunjukkan hasil terbaik pada eksperimen sebelumnya.

Experiment	Accuracy	Sensitivity	Specificity
1	80%	76.67%	83.33%
2	88.33%	90%	86.67%
3	83.33%	76.67%	86.67%
4	80%	73.33%	86.67%
5	86.67%	80%	93.33%
Average	83.67%	79.33%	87.33%

Tabel 6: Tingkat keberhasilan klasifikasi pada linear kernel

Experiment	Accuracy	Sensitivity	Specificity
1	75.00%	93.33%	56.67%
2	50.00%	63.33%	36.67%
3	56.67%	63.33%	50.00%
4	83.33%	73.33%	93.33%
5	71.67%	86.67%	56.67%
Average	67.33%	76%	58.67%

Tabel 7: Tingkat keberhasilan klasifikasi pada RBF kernel

Experiment	Accuracy	Sensitivity	Specificity
1	71.67%	73.33%	70.00%
2	76.67%	83.33%	70.00%
3	86.67%	73.33%	100%
4	71.67%	70.00%	73.33%
5	80.00%	66.67%	93.33%
Average	77.33%	73.33%	81.33%

Tabel 8: Tingkat keberhasilan klasifikasi pada polynomial of degree 3 kernel

Experiment	Accuracy	Sensitivity	Specificity
1	50%	100%	0%
2	50%	100%	0%
3	50%	100%	0%
4	50%	100%	0%
5	50%	100%	0%
Average	50%	100%	0%

Tabel 9: Tingkat keberhasilan klasifikasi pada sigmoid kernel

Classification menggunakan SVM dengan linear kernel menunjukkan accuracy terbaik dengan tingkat keberhasilan prediksi yang tinggi. Linear kernel SVM dengan 15-second epoch mencapai accuracy tertinggi di antara seluruh konfigurasi yang diuji.

V. KESIMPULAN

Dalam penelitian ini, kemungkinan untuk mendeteksi sleep apnea atau hypopnea events dari pola variasi sinyal ECG selama tidur telah dipelajari. Sebuah model yang menggunakan ECG signal features dikembangkan dan efektivitasnya dievaluasi. Model ini berbasis pada sekumpulan terpilih RR-interval-based

statistical features yang diberikan kepada SVM untuk proses classification. Model tersebut dievaluasi menggunakan lima variasi epoch length yang berbeda dan empat SVM kernel yang berbeda.

Berdasarkan hasil eksperimen, dapat disimpulkan bahwa detection dari sleep apnea atau hypopnea events menggunakan sinyal ECG dengan RR-interval-based statistical features menunjukkan accuracy terbaik ketika menggunakan SVM dengan linear kernel dan epoch length sebesar 15 detik, dengan tingkat accuracy yang tinggi yaitu sekitar 83.67%.

DAFTAR PUSTAKA

- [1] "Sleep disorder overview," www.neurologychannel.com, accessed: 2024.
- [2] "Sleep apnea: What is sleep apnea?" www.nhlbi.nih.gov, national Heart, Lung, and Blood Institute.
- [3] "Apnea guide," www.apneaguide.com.
- [4] American Thoracic Society, "Obstructive sleep apnea and heart disease," *Am J Respir Crit Care Med*, vol. 188, pp. P1–P2, 2013.
- [5] P. Chazal, T. Penzel, and C. Heneghan, "Automated detection of obstructive sleep apnoea at different time scales using the electrocardiogram," *Physiological Measurement*, vol. 25, no. 4, pp. 967–983, Aug 2004.
- [6] L. Almazaydeh, K. Elleithy, and M. Faezipour, "Detection of obstructive sleep apnea through ecg signal features," in *IEEE International Conference on Electro/Information Technology*, 2012.
- [7] A. Ng, J. Chung, M. Gohel, W. Yu, K. Fan, and T. Wong, "Evaluation of the performance of using mean absolute amplitude analysis of thoracic and abdominal signals for immediate indication of sleep apnoea events," *Journal of Clinical Nursing*, vol. 17, no. 17, pp. 2360–2366, Sep 2008.
- [8] E. Goldshtein, A. Tarasiuk, and Y. Zigel, "Automatic detection of obstructive sleep apnea using speech signals," *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 5, pp. 1373–1382, May 2011.
- [9] D. Alvarez, R. Hornero, D. Abasolo, F. Campo, and C. Zamarron, "Nonlinear characteristics of blood oxygen saturation from nocturnal oximetry for obstructive sleep apnoea detection," *Physiological Measurement*, vol. 27, no. 4, pp. 399–412, Apr 2006.
- [10] D. Alvarez, R. Hornero, J. Marcos, F. Campo, and M. Lopez, "Spectral analysis of electroencephalogram and oximetric signals in obstructive sleep apnea diagnosis," in *Proceedings of the 31st IEEE International Conference on Engineering in Medicine and Biology Society (EMBS 2009)*, Sep 2009, pp. 400–403.
- [11] B. Xie and H. Minn, "Real time sleep apnea detection by classifier combination," *IEEE Transactions on Information Technology in Biomedicine*, 2012, in Press.
- [12] R. Lin, R. Lee, C. Tseng, H. Zhou, C. Chao, and J. Jiang, "A new approach for identifying sleep apnea syndrome using wavelet transform and neural networks," *Biomedical Engineering: Applications, Basis & Communications*, vol. 18, no. 3, pp. 138–143, 2006.
- [13] Q. Manrique, A. Hernandez, T. Gonzalez, F. Pallester, and C. Dominquez, "Detection of obstructive sleep apnea in ecg recordings using time-frequency distributions and dynamic features," in *Proceedings of the IEEE International Conference on Engineering in Medicine and Biology Society (EMBS 2009)*, Sep 2009, pp. 5559–5562.
- [14] M. Schrader, C. Zywiets, V. Einem, B. Widiger, and G. Joseph, "Detection of sleep apnea in single channel ecgs from the physionet data base," *Computers in Cardiology 2000*, vol. 27, pp. 263–266, Sep 2000.
- [15] M. Mendez, D. Ruini, O. Villantieri, M. Matteucci, T. Penzel, and A. Bianchi, "Detection of sleep apnea from surface ecg based on features extracted by an autoregressive model," in *Proceedings of the IEEE International Conference on Engineering in Medicine and Biology Society (EMBS 2007)*, Aug 2007, pp. 6105–6108.

- [16] S. Isa, M. Fanany, W. Jatmiko, and A. Arymurthy, "Sleep apnea detection from ecg signal, analysis on optimal features, principal components, and nonlinearity," in *Proceedings of the 5th IEEE International Conference on Bioinformatics and Biomedical Engineering (iCBBE)*, May 2011, pp. 1–4.
- [17] A. S. Nugroho, A. B. Witarto, and D. Handoko, "Application of support vector machine in bioinformatics," in *Proceeding of Indonesian Scientific Meeting in Central Japan*, 2003.
- [18] H. Jambukia, Shweta, D. Vipul, and P. Harshadkumar, "Classification of ecg signals using machine learning techniques: A survey," in *International Conference on Advances in Computer Engineering and Applications (ICACEA)*, IMS Engineering College, Ghaziabad, India, 2015.