

Support Vector Classifier pada Tingkat Kenyamanan Termal dalam Kondisi Rileks Terhadap Perubahan Suhu Ruang Berbasis Sinyal EEG

¹Laurentius Kuncoro Probo Saputra, ²Ignatia Dhian E.K. Ratri

Informatika, Universitas Kristen Duta Wacana, Yogyakarta

kuncoro@staff.ukdw.ac.id

Abstrak

Kontrol suhu ruangan yang ada telah dikembangkan saat ini hanya memanfaatkan keadaan lingkungan/ruangan sebagai parameter untuk mengontrol suhu ruangan. Model kontrol seperti ini mengabaikan kondisi fisiologis dan psikologi seseorang yang sedang berada di dalam ruangan. Setiap orang memiliki tingkat kenyamanan yang berbeda-beda saat berada di dalam ruangan berpendingin. Kondisi nyaman tersebut dipengaruhi oleh termoregulasi seseorang untuk memenuhi kenyamanan termal. Sinyal EEG merupakan sinyal yang mampu merefleksikan aktivitas otak. Karena kenyamanan termal erat kaitannya dengan kondisi kepuasan pikiran atas kondisi termal lingkungan, maka sinyal EEG ini dirasa mampu merefleksikan tingkat kenyamanan termal seseorang. Penelitian ini akan menganalisa tingkat kenyamanan termal seseorang berbasis sinyal EEG. Sinyal EEG direkam menggunakan alat mindwave neurosky headset. Sinyal EEG direkam dalam kondisi rileks. Hasil data sinyal yang didapat akan dianalisis dan dilatihkan pada *classifier* SVC. Pengujian dilakukan dengan menggunakan metode k-fold validation dengan menggunakan nilai $k = 5$. Analisis lebih lanjut terkait performa keseluruhan dari *classifier* tersebut menggunakan kurva ROC. Hasil yang didapat dengan analisis kurva ROC ialah performa *classifier* SVC sebesar 87%.

Kata Kunci: support vector classifier, sinyal eeg, kenyamanan termal.

1 Pendahuluan

Penghematan energi sangat gencar dilakukan oleh berbagai pihak, baik dari pemerintah maupun dari pihak swasta. Salah satu penghematan energi dilakukan pada penelitian yang mengembangkan sistem kontrol suhu ruangan. Sistem kontrol suhu ruangan berdasarkan sensor thermostat di ruangan sudah banyak dikembangkan [1]–[3].

Beberapa sistem kontrol suhu ruangan yang ada hanya berdasarkan keadaan lingkungan ruangan. Sistem tersebut memanfaatkan sensor untuk mengukur keadaan lingkungan ruangan, seperti sensor suhu, kelembaban, ataupun sensor keberadaan seseorang di dalam ruangan. Model kontrol seperti itu mengabaikan karakteristik fisiologis yang terdapat pada setiap orang, seperti usia, jenis kelamin, kesehatan dan massa tubuh.

Beberapa penelitian lainnya telah mempertimbangkan kondisi fisiologi seseorang dalam membangun sistem kontrol suhu ruangan. Nakayama dkk. Nakayama serta Joon Ho Choi mengembangkan sistem kontrol suhu ruangan dengan melihat signal biologis, seperti suhu permukaan kulit dan detak jantung seseorang [4], [5]. Pola sinyal yang didapat melalui suhu permukaan kulit dan detak jantung lebih dapat menyediakan informasi mengenai kondisi kenyamanan termal individu saat itu.

Kenyamanan termal merupakan kondisi pikiran yang mengekspresikan kepuasan atas kondisi termal lingkungan sekitar. Kenyamanan termal individu ditentukan berdasarkan 6 variabel, yaitu: suhu udara, rata-rata suhu radiasi pencahayaan, kecepatan udara, kelembaban, pakaian, serta aktivitas yang dilakukan [5]. Berdasarkan SNI 03-6572-2001, suhu udara juga merupakan salah satu faktor yang mempengaruhi kenyamanan termal individu. Daerah kenyamanan termal individu untuk daerah tropis antara $20,5^{\circ}\text{C} \sim 27,1^{\circ}\text{C}$, yang terbagi menjadi 3 yaitu sejuk nyaman, nyaman optimal, dan hangat nyaman.

Kenyamanan termal individu sangat erat kaitannya dengan kondisi fisik dan psikologi seseorang. Ketika seseorang mendapatkan atau kehilangan panas yang berlebih, sistem termoregulasi seseorang mungkin tidak mampu menjaga keseimbangan suhu, maka akan menyebabkan ketidaknyamanan termal seperti terlalu hangat atau panas dan terlalu dingin. Ketidaknyamanan termal erat kaitannya dengan tingkat stres, sehingga berdampak pada kinerja dan kesehatan seseorang [5].

Kondisi stres maupun rileks merupakan hasil dari tanggapan otak terhadap rangsangan yang berasal dari luar. Sinyal electrocephalogram (EEG) dapat dengan langsung merefleksikan aktivitas elektrik otak. Sinyal EEG merupakan sinyal yang sangat kompleks. Sinyal EEG inilah yang menjadi sumber informasi untuk mempelajari fungsi dan keadaan otak manusia, sehingga banyak digunakan. Beberapa penelitian telah dilakukan untuk mengetahui aktivitas otak yang erat kaitannya dengan kondisi stres maupun rileks [6]–[8]. Kondisi nyaman dalam sebuah ruangan sangat mendukung sekali dalam meningkatkan produktivitas seseorang dan kesehatan. Salah satu faktor yang

mendukung ialah kondisi suhu ruangan yang dapat menyesuaikan terhadap kondisi masing-masing individu.

Permasalahan yang dihadapi ialah tiap orang memiliki tingkat kenyamanan termal berbeda-beda di rentang kondisi suhu ruangan 20°C - 34°C . Penerapan sistem kontrol suhu ruangan yang adaptif dengan memperhatikan kondisi tiap orang dapat membuat kenyamanan termal seseorang tercapai. Tingkat kenyamanan termal seseorang akan ditentukan dengan pengukuran menggunakan sinyal EEG dari otak yang ditangkap oleh headset Mindwave Neurosky serta pengolahan data-data sinyal EEG. Pengolahan data akan menghasilkan sistem yang dapat mengklasifikasikan kondisi tingkat kenyamanan termal seseorang pada 3 kondisi suhu ruangan.

2 Tinjauan Pustaka Dan Landasan Teori

2.1 Tinjauan Pustaka

Penelitian mengenai sinyal EEG telah banyak dilakukan oleh para peneliti terutama berkaitan dengan analisis sinyal EEG untuk mengetahui kondisi atau aktivitas otak manusia serta penelitian mengenai kenyamanan termal seseorang. Sub-bab ini memberikan beberapa kajian dari beberapa penelitian sebelumnya mengenai analisis sinyal EEG dan kenyamanan termal seseorang.

Joon Hoi Choi [5] melakukan penelitian mengenai kondisi nyaman termal seseorang dengan melihat bio-feedback yang berasal dari kondisi suhu permukaan kulit dan kondisi detak jantung saat kenyamanan termal seseorang tercapai atau tidak. Tujuan dari penelitiannya ialah membuat sebuah sistem adaptive yang dikontrol berdasarkan bio-feedback seseorang.

Saidatul dkk [8] melakukan penelitian untuk melihat perubahan sinyal EEG seseorang pada kondisi rileks dan kondisi stress. Kondisi rileks seseorang didapatkan dengan mengkondisikan orang tersebut pada kondisi duduk secara nyaman dan diperlihatkan sebuah video. Kondisi stress didapatkan dengan memberikan sebuah tugas aritmatika untuk dikerjakan. Ekstraksi fitur berdasarkan pada perhitungan power spectral density (PSD). Backpropagation neural network digunakan untuk melakukan klasifikasi kondisi rileks atau stress. Hasil penelitian Saidatul dkk memperlihatkan bahwa akurasi klasifikasi tertinggi didapatkan sebesar 91,17% dengan menggunakan metode Burg pada pengukuran power spectral density.

Xiyuan Hou dkk. [6] melakukan penelitian untuk mengukur tingkat stress seseorang. Penelitiannya

menggunakan responden sebanyak 9 orang dan membagi tingkat stress menjadi 4 tingkat. Analisis tingkat stress menggunakan 3 kombinasi fitur yaitu power, fractal dimension, dan statistika. Pengklasifikasian dilakukan dengan menggunakan 2 metode klasifikasi yaitu SVM dan k-NN. Dari hasil penelitiannya, akurasi klasifikasi tertinggi didapatkan apabila hanya menggunakan 2 tingkatan stress dengan akurasi sebesar 85,17%. Sedangkan 3 tingkatan stress memiliki akurasi sebesar 75,22%, dan untuk 4 tingkatan stress memiliki akurasi sebesar 67,07%.

Muhammad dkk. [7] mengimplementasikan perangkat low-cost untuk merekam sinyal EEG sehingga dapat mengukur stress seseorang. Validasi kondisi stress seseorang dilakukan dengan menggunakan kuesioner PSS. Hasil dari kuesioner PSS digunakan untuk melabelkan orang tersebut apakah dalam keadaan stress atau tidak. Pengklasifikasian kondisi stress seseorang menggunakan 3 buah metode klasifikasi yaitu, Naïve Bayes, SVM, dan MLP. Dari hasil penelitiannya, metode SVM memiliki akurasi tertinggi mencapai 71,42%.

Lim dan Chia [9] melakukan penelitian pengukuran tingkat kognitif stress dengan menggunakan sinyal EEG yang berasal dari 1 elektroda. Responden yang digunakan sebanyak 25 orang. Metode pengenalan yang digunakan ialah Artificial Neural Network (ANN), k-Nearest Neighbor (k-NN), dan Linear Discriminant Analysis (LDA). Metode pengenalan tersebut dilatihkan dengan menggunakan fitur dari 2% DCT. Hasil yang didapatkan memperlihatkan bahwa k-NN mampu mencapai akurasi klasifikasi hingga 72% dibandingkan dengan ANN dan LDA.

2.2 Landasan Teori

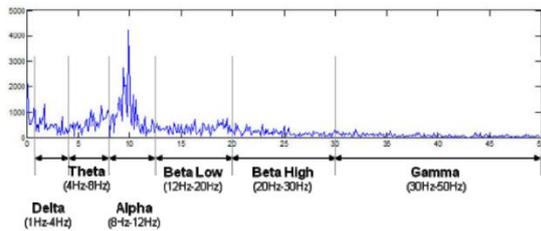
2.2.1 Sinyal Electrocephalograph



Gambar 1. Sinyal EEG 1 elektroda

EEG atau electrocephalograph merupakan sebuah sinyal yang merepresentasikan aktivitas elektrik otak. Gambar 1 menampilkan sinyal EEG 1 elektroda yang direkam menggunakan aplikasi openVibe. EEG dapat digunakan untuk mempelajari fungsi otak manusia. Proses mendapatkan sinyal elektrik menggunakan sebuah elektroda yang ditempelkan pada lapisan kulit kepala. Elektroda berkerja untuk merekam sinyal elektrik otak yang memiliki skala tegangan microvolt. Sinyal EEG memiliki beberapa area frekuensi yang mengindikasikan karakteristik tertentu [10], yaitu:

Delta (1-4 Hz), Theta (4-8 Hz), Alfa atau Mu (8-12 Hz), Beta (12-30 Hz), Gamma (30-45 Hz).



Gambar 2. Pembagian Spektrum Frekuensi Sinyal EEG

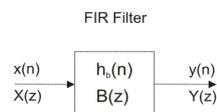
Gambar 2 memperlihatkan spectrum frekuensi masing-masing area frekuensi sinyal EEG. Masing-masing spektrum frekuensi kelompok gelombang EEG juga memiliki karakteristik amplitudo sinyal. Tabel 1 memperlihatkan karakteristik amplitudo sinyal disetiap gelombang EEG dalam satuan mikro volt (μV).

Tabel 1. Karakteristik Amplitudo Sinyal EEG

| Nama Gelombang | Amplitudo (μV) |
|----------------|-----------------------------|
| Delta | 100-200 |
| Theta | > 30 |
| Alfa | 30 - 50 atau lebih |
| Beta | 2 - 20 atau lebih |
| Gamma | 2. - 5 atau lebih |

2.2.2 Filter FIR

Filter FIR merupakan filter yang tidak memiliki umpan balik. Filter FIR memiliki karakteristik fase yang linear. Di sisi lain, apabila sebuah sistem sangat memperhitungkan karakteristik fase, maka filter FIR akan menjadi solusi terbaik untuk digunakan. Blok diagram sebuah filter FIR diperlihatkan oleh Gambar 3. Berdasarkan blok diagram tersebut, sebuah persamaan dari filter FIR dapat ditulis seperti pada Persamaan 2.1. memperlihatkan sebuah struktur filter FIR dengan order $N=1$.



Gambar 3. Blok Diagram Filter FIR

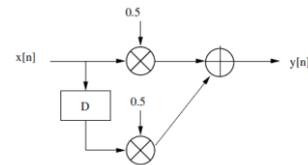
$$y(n) = h_b(n) * x(n) \quad [2.1]$$

$$y[n] = \sum_{k=0}^N x[k]h[n-k] \quad [2.2]$$

$$y[0] = 0,5x[0] + 0,5x[-1] \quad [2.3]$$

$$y[1] = 0,5x[1] + 0,5x[0] \quad [2.4]$$

$$y[n] = 0,5x[n] + 0,5x[n-1] \quad [2.5]$$



Gambar 4. Filter FIR dengan koefisien {0,5;0,5}

Persamaan 2.1 memperlihatkan persamaan umum sebuah filter FIR. Berdasarkan persamaan umum tersebut, struktur filter FIR dapat dituliskan seperti pada Persamaan 2.2 - 2.5. Persamaan 2.5 dapat digambarkan seperti pada Gambar 4. Sebuah filter dapat didesain dengan berbagai metode. Tetapi pada dasarnya, sebuah desain filter berdasarkan metode pendekatan sebuah filter ideal. Tujuan akhir ialah mendapatkan filter seideal mungkin, tetapi itu merupakan hal yang tidak mungkin. Sehingga, desain filter dibuat sedemikian menyerupai karakteristik filter ideal.

2.2.3 Fourier Transform

Transformasi Fourier digunakan untuk mentransformasikan sinyal kontinyu pada domain waktu ke domain frekuensi. Transformasi Fourier mendeskripsikan spektrum kontinyu dari sinyal non-periodik. Transformasi Fourier $X(f)$ dari waktu kontinyu $x(t)$ dirumuskan seperti pada Persamaan 2.6 berikut:

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \quad [2.6]$$

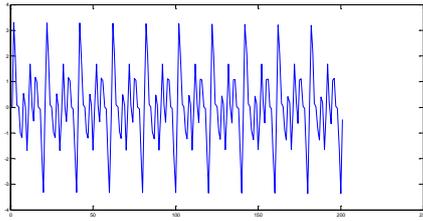
Supaya Transformasi Fourier dapat digunakan dalam operasi digital, maka diperlukan sampel-sampel pada kawasan waktu. Sampel-sampel sinyal kontinyu pada kawasan waktu akan merepresentasikan keseluruhan sinyal kontinyu tersebut. Sampel-sampel ini akan mengubah sinyal kontinyu menjadi sinyal diskrit, maka dibutuhkan Transformasi Fourier untuk sinyal diskrit yang sering dikenal dengan Discrete Fourier Transform (DFT). Discrete Fourier Transform diformulasikan seperti Persamaan 2.7:

$$X[k] = \sum_{n=0}^{N-1} x[n]W_N^{kn} \quad [2.7]$$

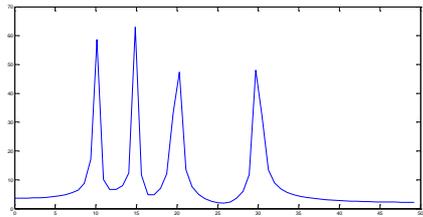
dengan:

$$W_N = e^{-j(\frac{2\pi}{N})}$$

Sinyal diskrit pada domain waktu akan ditransformasikan ke dalam domain frekuensi seperti yang terlihat pada Gambar 5.



(a) Sinyal Kontinyu pada Domain Waktu



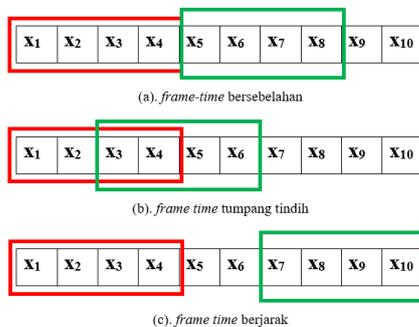
(b) Spektrum Frekuensi Sinyal

Gambar 5. (a) Sinyal Kontinyu, (b) Spektrum Frekuensi

2.2.4 Fitur Sinyal

Sinyal EEG yang telah didapatkan dalam proses pengambilan data untuk 7 responden akan dilakukan ekstraksi fitur. Fitur didapatkan dari hasil olahan data dari domain spasial maupun frekuensi untuk setiap sinyal. Proses ekstraksi fitur dilakukan dengan maksud untuk melihat komponen frekuensi dan spektral dari setiap bingkai waktu dan frekuensi pada sinyal EEG. Setiap bingkai waktu dan nilai dalam domain frekuensi informasi yang unik.

Sinyal EEG berbentuk rentetan data dalam domain waktu. Sehingga, proses pengambilan banyaknya data dengan cara time-frame. Pengambilan data dengan membagi dalam bentuk frame-time bisa menggunakan model seperti Gambar 6. Setiap time-frame akan dilakukan ekstraksi fitur. Setiap time-frame yang diekstraksi akan terkena overlapping sebesar n-sample. Fitur spasial dan frekuensi dari sinyal EEG akan digunakan sebagai fitur yang akan membedakan dan mengelompokkan kenyamanan termal seseorang.



Gambar 6. Model Pencuplikan frame-time

Fitur Average Band Value

Feature ini didapatkan dengan merata-rata nilai magnitude dari hasil *Fourier Transform (FT)* dalam 1 kelompok spektrum pita frekuensi pada sinyal EEG seperti pada **Error! Reference source not found.**

$$avgBandValue_i = \overline{abs(X[k]_i)}$$

dimana:

$X[k]$ = koefisien FT

i = kelompok pita frekuensi ke- i , dengan:

$i = 1 \rightarrow$ frekuensi 1 - 4 Hz

$i = 2 \rightarrow$ frekuensi 4 - 8 Hz

$i = 3 \rightarrow$ frekuensi 8 - 12 Hz

$i = 4 \rightarrow$ frekuensi 12 - 20 Hz

Fitur Higuchi Fractal Dimension (HFD)

Fitur ini menghitung dimensi fraktal pada domain waktu. HFD berdasarkan pada panjang $L(k)$ sebuah kurva yang merepresentasikan cuplikan waktu sesaat menggunakan segmen sampel k sebagai sebuah unit [11].

$$L(k) \sim k^{-D_f} \quad [2.8]$$

Fitur Petrosian Fractal Dimension (PFD)

Fitur ini dapat digunakan untuk melakukan perhitungan cepat untuk menerjemahkan data dalam deret waktu ke dalam bentuk binerisasi [12]. Algoritma ini akan menetapkan nilai biner '1' untuk setiap perbedaan antara sampel yang berurutan didalam deret waktu yang melebihi standar deviasi dan biner '0' untuk sebaliknya.

$$FD_{Petrosian} = \frac{\log_{10} n}{\log_{10} n + \log_{10} n \left(\frac{n}{n + 0.4N_{\Delta}} \right)} \quad [2.9]$$

Fitur Multiscale Entropy Analysis (MSE)

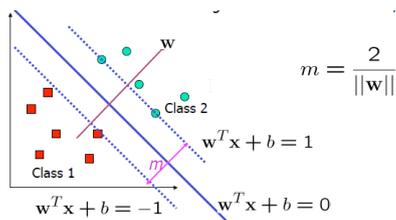
Fitur ini dapat mengukur kompleksitas dari sebuah deret waktu terbatas [13]. MSE menggunakan Algoritma S_E untuk menghitung nilai entropy di setiap skala waktu.

$$S_E(m, r, N) = -\ln \frac{\phi^{m+1}(r)}{\phi^m(r)} \quad [2.10]$$

Complexity Index:

$$C_I = \sum_{i=1}^N S_E(i) \quad [2.10]$$

2.2.5 Support Vector Classifier (SVC)

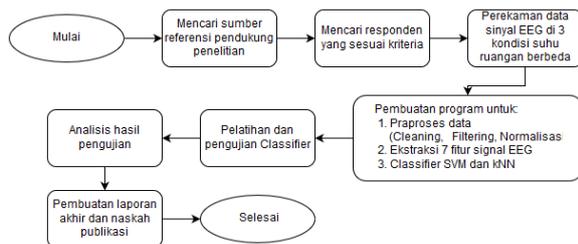


Gambar 7. Ilustrasi SVC

SVC bekerja berdasarkan perhitungan statistic. Jika terdapat 2 kelas dapat dengan mudah dipisahkan dengan sebuah garis linear, seperti Gambar 7. SVC akan mencari sebuah garis pemisah dengan memaksimalkan jarak dari setiap kelas yang ada.

3 Metodologi Penelitian

Dalam melakukan penelitian ini, beberapa proses utama yang harus dilakukan yaitu pengumpulan responden, pengambilan data, pengolahan data, analisis data. Tahapan penelitian ini diperlihatkan seperti pada Gambar 8. Penelitian diawali dengan pengumpulan referensi pendukung untuk melakukan pengambilan data signal EEG dan beberapa prosedur yang harus digunakan. Pengambilan data signal EEG ini menggunakan data yang diambil langsung dari responden. Setiap responden akan mengalami berada di 3 kondisi suhu ruangan, yaitu dingin, normal, dan panas. Sehingga dalam proses pengambilan data, responden harus benar-benar dalam keadaan yang sehat.



Gambar 8. Alur Penelitian

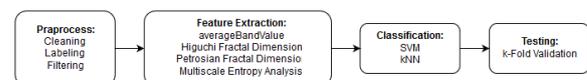
3.1 Pengambilan Data

Awal pengambilan data, responden akan diperiksa kondisi tubuhnya, baik suhu tubuh. Pemeriksaan ini dilakukan untuk memastikan bahwa responden dalam keadaan sehat sehingga proses pengambilan data bisa lebih valid. Kemudian setelah itu, responden akan diberikan waktu 10 menit untuk beristirahat setelah menyelesaikan kuesioner tersebut. Langkah berikutnya adalah responden ditempatkan pada 3 kondisi suhu ruangan yang berbeda dan melakukan kegiatan yang sama. Kondisi yang terdapat dalam ruangan I adalah suhu dingin yang memiliki suhu 16 - 21 °C,

kemudian ruangan II adalah ruangan dengan suhu normal yaitu 21 - 26 °C dan yang terakhir ruangan III adalah ruangan dengan suhu panas (lebih dari 27 °C).

Pada saat responden berada dalam ruangan, responden akan dikondisikan pada kondisi rileks selama 10 menit. Penelitian ini akan menghasilkan 15 data dari 10 responden tersebut. Masing-masing responden memiliki dari 5 data signal EEG dari 3 model ruangan yang sudah dipersiapkan. Sehingga total data yang didapatkan adalah 150 data signal EEG.

3.2 Implementasi Sistem



Gambar 9. Alur Sistem

Proses ini terdiri dari beberapa tahapan yaitu: praproses, ekstraksi fitur, pembentukan classifier, dan pengujian classifier. Alur setiap proses diperlihatkan pada Gambar 9.

3.2.1 Praproses

Tahapan ini terdiri dari beberapa proses di dalamnya, yaitu: Cleaning, Labeling, Filtering, dan Normalisasi. Proses cleaning bertujuan untuk menghilangkan data signal yang rusak diakibatkan karena pada proses pengambilan data, elektroda tidak menempel secara benar pada kepala. Proses labeling bertujuan untuk memberikan label nyaman atau tidak nyaman dalam setiap data signal EEG. Labeling ini akan digunakan dalam classification sebagai target pembelajaran. Proses filtering bertujuan untuk menghilangkan signal noise yang ikut terekam pada proses pengambilan data. Signal noise bisa bersumber dari frekuensi listrik AC, dan gerakan mata dan mulut.

3.2.2 Feature Extraction

Tahap ini akan mengekstrak signal EEG ke dalam 4 fitur utama, yaitu: averageBandValue, Higuchi Fractal Dimension (HFD), Petrosian Fractal Dimension (PFD), dan Multiscale Entropy Analysis (MSE). Empat fitur tersebut akan menghasilkan 7 nilai fitur, dimana fitur averageBandValue menghasilkan 4 nilai, HFD menghasilkan 1 nilai, PFD menghasilkan 1 nilai, dan MSE menghasilkan 1 nilai.

3.2.3 Classification

Proses ini merupakan proses pelatihan sebuah classifier agar dapat mengelompokkan data signal sesuai dengan target label yang telah ditentukan. Classifier yang digunakan ialah Support Vector Classifier (SVC).

3.2.4 Testing

Proses testing bertujuan untuk menguji classifier yang sudah dilatihkan pada tahap sebelumnya. Pengujian menggunakan data baru yang tidak pernah dilatihkan sebelumnya. Proses testing ini menggunakan metode k-Fold Validation. Metode ini akan membagi data set yang ada menjadi bagian pelatihan dan pengujian. Pada penelitian ini, fold yang digunakan yaitu sebanyak 5-fold. Penggunaan k-Fold Validation ini untuk menghindari nilai akurasi classifier yang bias.

3.3 Analisis Hasil Pengujian

Analisis pengujian dengan melihat performa dari classifier berdasarkan data set yang digunakan dalam pelatihan. Performa classifier ditampilkan dalam bentuk kurva Receiver Operating Characteristic (ROC). Kurva ROC dibentuk dari 2 parameter penilaian, yaitu: true positive rate dan false positive rate.

4 Hasil Dan Pembahasan

4.1 Pengambilan Data

Berdasarkan isian dari 7 responden, kondisi yang membuat responden merasa rileks yaitu mendengarkan musik sambil duduk/ tidur, meditasi, dan berada di ruangan yang sunyi. Oleh karena itu, kondisi yang dibuat saat pengambilan data ialah responden diminta duduk santai di sebuah kursi yang nyaman sambil mendengarkan musik yang disukainya. Kondisi responden saat pengambilan data diperlihatkan pada Gambar 10.

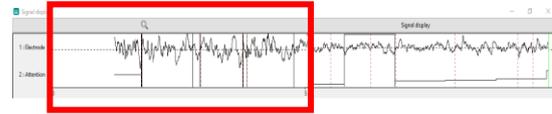


Gambar 10. Kondisi responden saat pengambilan data

Pengambilan data dilakukan kepada 7 responden, yaitu 5 pria dan 2 wanita. Setiap responden akan diambil 3 data untuk setiap kondisi suhu ruangan. Sehingga total data yang digunakan untuk proses selanjutnya ialah 63 data sinyal dengan perekaman ± 10 menit. Perekaman sinyal EEG menggunakan frekuensi sampling sebesar 512 data/ detik. Setiap kali pengambilan data, responden akan mengisi tingkat kenyamanannya saat itu dengan suhu yang sudah diatur. Tingkat kenyamanan dikelompokkan menjadi 2, yaitu nyaman dan tidak nyaman. Data sinyal yang direkam akan dilabelkan sesuai dengan

tingkat kenyamanan yang dirasakan oleh responden.

4.2 Preprocessing

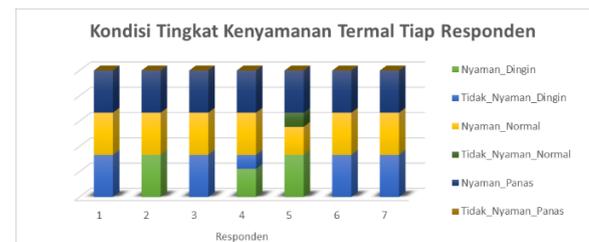


Gambar 11. Data sinyal yang dibersihkan pada 5 detik pertama

Proses *cleaning* dilakukan untuk membersihkan data sinyal yang rusak dari hasil perekaman. Sinyal yang rusak merupakan sinyal yang direkam saat inisialisasi yaitu di 5 detik pertama (Gambar 11), dan juga sinyal yang disebabkan karena putusnya kontak fisik antara elektroda headset dengan dahi responden, sehingga mengakibatkan sinyal tidak terbaca oleh headset Neurosky. Kondisi ini bisa disebabkan karena kelembaban kulit pada dahi responden, kondisi alat yang sudah terlalu lama menyala, dan juga posisi elektroda yang tidak sesuai.

Tabel 2. Jumlah data berdasar tingkat kenyamanan termal

| Respon- den | Suhu Dingin (Jml Data) | | Suhu Normal (Jml Data) | | Suhu Panas (Jml Data) | |
|----------------|---------------------------|----------|---------------------------|----------|--------------------------|----------|
| | Nyaman | T_Nyaman | Nyaman | T_Nyaman | Nyaman | T_Nyaman |
| 1 | 0 | 3 | 3 | 0 | 3 | 0 |
| 2 | 3 | 0 | 3 | 0 | 3 | 0 |
| 3 | 0 | 3 | 3 | 0 | 3 | 0 |
| 4 | 2 | 1 | 3 | 0 | 3 | 0 |
| 5 | 3 | 0 | 2 | 1 | 3 | 0 |
| 6 | 0 | 3 | 3 | 0 | 3 | 0 |
| 7 | 0 | 3 | 3 | 0 | 3 | 0 |



Gambar 12. Kondisi tingkat kenyamanan termal tiap responden

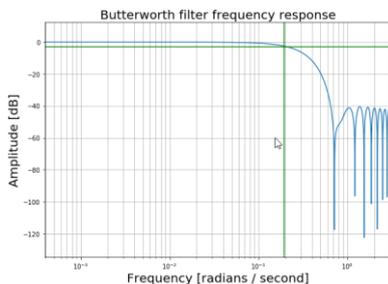
Proses labeling dilakukan berdasarkan form isian responden terkait tingkat kenyamanan yang dirasakan. Dari hasil isian tingkat kenyamanan termal responden, dapat dituliskan pada Tabel 2 dan digambarkan pada Gambar 12. Dari data yang didapat dapat dilihat bahwa tingkat kenyamanan termal seseorang berbeda-beda. Ada responden yang merasakan nyaman di seluruh kondisi suhu. Empat responden merasakan tidak nyaman di kondisi dingin.

Selanjutnya, proses *filtering* dilakukan untuk menghilangkan noise pada signal EEG. Filter digital dibangun dengan model *Finite Impulse Response* (FIR). Pembuatan model filter digital FIR menggunakan *library* *scipy* (<https://www.scipy.org/>) dalam bahasa python.

```
In [ ]: b = signal.firwin(20, 0.195, window='hamming', fs=512)
w, h = signal.freqz(b, worN=8000)
```

Gambar 13. Code desain filter

Hasil desain filter FIR dengan code di Gambar 13 menghasilkan frekuensi respon seperti pada Gambar 14.



Gambar 14. Frekuensi respon filter FIR

4.3 Feature Extraction

Satu file perekaman signal EEG memiliki durasi selama ± 10 menit dengan $F_s = 512$ Hz. Proses feature extraction dilakukan untuk setiap time frame 20 detik dengan jarak pengambilan time frame selanjutnya ialah 10 detik. Sehingga, dalam 1 file perekaman, bisa mendapatkan time frame sebanyak 20 buah. Setiap time frame akan diproses untuk mendapatkan 7 nilai feature. *Feature extraction* menggunakan *library* *eeglib* (<https://github.com/Xiul109/eeglib>) dengan code seperti pada Gambar 15.

```
i = 0
for eeg in helper[:,overlap]:
    avg = eeg.getAverageBandValues()

    feature[i][0] = avg[0]['delta']
    feature[i][1] = avg[0]['theta']
    feature[i][2] = avg[0]['alpha']
    feature[i][3] = avg[0]['beta']
    feature[i][4] = eeg.HFD()
    feature[i][5] = eeg.PFD()
    feature[i][6] = eeg.MSE(0)
```

Gambar 15. Code feature extraction

Contoh hasil 5 *time frame* dengan masing-masing 7 *feature*:

```
'delta', 'theta', 'alpha', 'beta', 'hfd', 'pfd', 'mse'
5.9234 , 5.8790 , 4.4026 , 1.1454 , 2.0681 , 1.0026 , 0.00740
4.2476 , 4.6365 , 3.4119 , 1.0090 , 2.0882 , 1.0025 , 0.00860
2.7721 , 2.8693 , 2.6937 , 0.6819 , 2.0767 , 1.0027 , 0.01280
2.3430 , 2.6321 , 2.8661 , 0.6598 , 2.0746 , 1.0027 , 0.01530
2.4480 , 2.4254 , 2.4961 , 0.7205 , 2.0795 , 1.0029 , 0.02040
```

Feature extraction menghasilkan matrix *feature* dengan dimensi [1337,7]. Jumlah sampel yang

didapat dari banyaknya *time frame* yang terbentuk ialah 1337, dan memiliki 7 nilai *feature*.

4.4 Classification

Pelatihan dilakukan dengan menggunakan *classifier* SVC. Sebelum dilakukan pelatihan, proses normalisasi dilakukan untuk mengubah rentang nilai *feature* menjadi 0 – 1. Selanjutnya dari 1337 sampel dibagi menjadi 2 bagian, bagian untuk pelatihan dan untuk pengujian (*testing*). Proses pelatihan menggunakan *library* *sklearn* (<http://scikit-learn.org/stable/>) dalam bahasa python. Langkah pertama yang perlu dilakukan ialah membuat model *classifier* SVC. *Classifier* SVC di bangun dengan kernel *radial basis function*.

```
#build classifier using svc (support vector classifier)

classifier =
svm.SVC(kernel='rbf', probability=True, random_state=1234)
```

Hasil dari model *classifier* yang telah dibangun, maka *classifier* tersebut siap digunakan untuk melatih serta menguji data yang sudah terbagi dalam *k-Fold*.

```
scores = cross_val_score(classifier, X, y, cv=cv)
print('Scores on each CV fold: %s' % scores)
print('Mean score: %s' % np.mean(scores))
```

4.5 Pengujian

Proses *testing* dilakukan dengan membagi 1337 sampel data mejadi 75% merupakan data untuk *training* dan 25% merupakan data *testing*. Sampel *training* dan *testing* dengan 5-fold dibagi secara acak dengan fungsi *ShuffleSplit*. Agar proses pengacakan selalu sama setiap kali dijalankan, maka nilai *random_state* harus ditentukan.

```
cv=ShuffleSplit(n_splits=5, test_size=.25, random_state=1234)
```

Hasil dari pengujian dengan menggunakan *k-fold validation* dengan nilai $k=5$ ditunjukkan pada Tabel 3. Dari hasil pengujian tersebut didapatkan akurasi sebesar 82,47%. Nilai akurasi ini belum bisa menjadi patokan, karena pengujian dengan *k-Fold* hanya dilakukan dengan sekali pengacakan sampel *testing*.

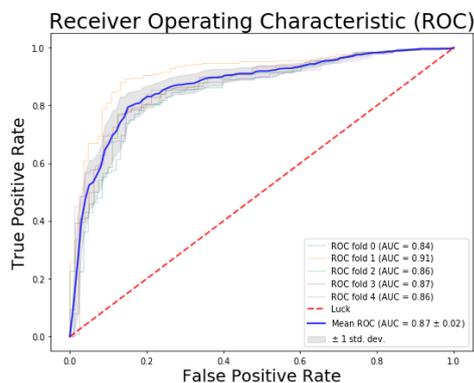
Tabel 3. Hasil Pengujian k-Fold dengan nilai $k=5$

| Fold | Akurasi (%) |
|-----------|-------------|
| 1 | 82,09 |
| 2 | 84,32 |
| 3 | 82,09 |
| 4 | 82,84 |
| 5 | 81,34 |
| Rata-rata | 82,53 |

Kurva *Receive Operating Characteristic* (ROC) dibuat untuk memperlihatkan performa *classifier* dalam menghadapi berbagai variasi data sampel

baru maupun data set yang tidak seimbang. Hasil dari pengujian dibentuk dengan kurva ROC diperlihatkan pada Gambar 16.

Dari hasil yang telah didapatkan dalam pembangunan sistem klasifikasi dengan SVC, nilai rata-rata ROC yang diukur dari luas area di bawah grafik (AUC/ *area under curve*) sebesar 0,87 dengan nilai maksimal 1. Kurva ROC juga memperlihatkan besaran nilai rata-rata AUC dari setiap *fold*. Kurva ROC pada Gambar 16 dibentuk dengan pengujian sebanyak 100 kali pengacakan data sehingga setiap *fold*-nya akan membentuk 1 buah kurva.



Gambar 16. Kurva ROC

5 Kesimpulan

Tingkat kenyamanan termal seseorang berbeda-beda, tidak bisa dikelompokkan berdasarkan suhu ruangan. Prediksi dari hasil klasifikasi berdasarkan data *time frame* setiap signal EEG untuk mendeteksi tingkat kenyamanan termal seseorang mendapatkan nilai performa akurasi secara keseluruhan sebesar 87%.

6 Ucapan Terima Kasih

Penelitian ini didanai oleh Direktorat Riset dan Pengabdian Masyarakat Direktorat Jendral Penguatan Riset dan Pengembangan, Kementerian Riset, Teknologi dan Pendidikan Tinggi (Penelitian Dosen Pemula) No. 109/SP2H/LT/DRPM/2018. Kami juga mengucapkan terima kasih kepada Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) dan Fakultas Teknologi Informasi (FTI) Universitas Kristen Duta Wacana.

7 Daftar Pustaka

[1] Z. Cheng, W. W. Shein, Y. Tan, and A. O. Lim, "Energy efficient thermal comfort control for cyber-physical home system," *2013 IEEE Int. Conf. Smart Grid Commun.*

SmartGridComm 2013, pp. 797–802, 2013.

[2] A. Solfia, Ya'umar, and W. A. Asmoro, "Rancang bangun sistem ac otomatis berbasis mikrokontroler atmega 8535 pada," pp. 1–12.

[3] S. M. Zanolli and D. Barchiesi, "Thermal and lighting control system with energy saving and users comfort features," *2012 20th Mediterr. Conf. Control Autom. MED 2012 - Conf. Proc.*, pp. 1322–1327, 2012.

[4] K. Nakayama, T. Suzuki, and K. Kameyama, "Estimation of thermal sensation using human peripheral skin temperature," *Syst. Man Cybern.*, no. October, pp. 2872–2877, 2009.

[5] J. H. Choi, "CoBi: Bio-Sensing Building Mechanical System Controls for Sustainably Enhancing Individual Thermal Comfort," *PHD Diss.*, no. May, 2010.

[6] X. Hou et al., "EEG based Stress Monitoring," *IEEE Int. Conf. Syst. Man Cybern.*, no. November, pp. 3110–3115, 2015.

[7] S. Muhammad and U. Saeed, "Psychological Stress Measurement Using Low Cost Single Channel EEG Headset," pp. 581–585, 2015.

[8] A. Saidatul, M. P. Paulraj, and S. Yaacob, "Analysis of EEG signals during relaxation and mental stress condition using AR modeling techniques," pp. 477–481, 2011.

[9] L. Chee-Keong Alfred and W. Chong Chia, "Analysis of Single-Electrode EEG Rhythms Using MATLAB to Elicit Correlation with Cognitive Stress," *Int. J. Comput. Theory Eng.*, vol. 7, no. 2, pp. 149–155, 2015.

[10] Z. Khalili and M. H. Moradi, "Emotion recognition system using brain and peripheral signals: Using correlation dimension to improve the results of EEG," *2009 Int. Jt. Conf. Neural Networks*, pp. 1571–1575, 2009.

[11] T. Quang, D. Khoa, V. Q. Ha, and V. Van Toi, "Higuchi Fractal Properties of Onset Epilepsy Electroencephalogram," vol. 2012, 2012.

[12] C. Goh et al., "Comparison of Fractal Dimension Algorithms for the Computation of EEG Biomarkers for Dementia To cite this version : HAL Id : inria-00442374," 2009.

[13] M. A. Busa and R. E. A. Van Emmerik, "Multiscale entropy: A tool for understanding the complexity of postural control," *J. Sport Heal. Sci.*, vol. 5, no. 1, pp. 44–51, 2016.