

Klasifikasi Keadaan Mata berdasarkan Sinyal Electroencephalography Menggunakan Gaussian Process

Aditya Arya Mahesa¹, Untari Novia Wisesty², Adiwijaya³

^{1,2,3}Fakultas Informatika, Universitas Telkom, Bandung

¹adityamahesa@student.telkomuniversity.ac.id, ²untari.nw@telkomuniversity.ac.id,

³adiwijaya@telkomuniversity.ac.id

Abstrak

Electroencephalography (EEG) merupakan pemantauan sinyal dimana sinyal tersebut dipancarkan oleh otak dan diterima oleh elektroda. Hasil pemindaian sinyal-sinyal tersebut dapat diterapkan menjadi antarmuka komputer-otak (Brain-computer Interface, BCI). Banyak sekali penerapan dari BCI ini, salah satunya adalah klasifikasi kondisi mata, baik terbuka maupun tertutup. Agar kondisi mata dapat dikenal melalui sinyal otak, maka dibutuhkan metode klasifikasi untuk melakukannya. Pada artikel ini, Gaussian Process diterapkan sebagai classifier untuk mengklasifikasi kondisi mata tersebut. Untuk performansi, classifier Gaussian Process telah mencapai akurasi sejumlah 98.663%, presisi 98.283%, recall 98.849%, dan f1-score senilai 98.565%, dengan menggunakan Matérn sebagai fungsi kovarian dengan parameter $\nu = \frac{3}{2}$, perbandingan data testing dan data training sejumlah 1:9, dan satu kali iterasi Newton.

Kata kunci: Electroencephalography, Brain-computer Interface, Kondisi mata, Gaussian Process

Abstract

Electroencephalography (EEG) is a signal monitoring which observes brain waves through electrodes. This set of signals can be applied to Brain-computer Interface (BCI). There are many applications of BCI, one of them can classify the Eye-state, both eyes open or closed. For those signals recognizing, it needs to determine a method of classifier system. In this article, Gaussian Process is implemented as probabilistic classifier to categorize Eye-state based on Electroencephalography signal. For performance, Gaussian Process classifier had reached 98.663% accuracy, 98.283% precision, 98.849% recall, and 98.565% of f1-score, with using Matérn as covariance function with parameter parameter $\nu = \frac{3}{2}$, testing-training ratio 1:9, and one time of Newton's iterations.

Keywords: Electroencephalography, Brain-computer Interface, Eye-state, Gaussian Process

1. Pendahuluan

Latar Belakang

Electroencephalography (EEG) merupakan sinyal yang dipancarkan oleh gelombang otak yang diterima oleh elektroda [5]. Banyak hal yang dapat dimanfaatkan dari sinyal EEG ini, dimana dibentuklah sebuah konsep antarmuka komputer-otak (Brain-computer Interface, BCI). Dengan diterapkannya BCI, maka manusia tidak perlu menggerakkan otot atau syaraf motorik untuk melakukan aktivitas, melainkan cukup menggunakan aktivitas otak [4]. BCI sudah diterapkan mulai dari pemindaian emosi ataupun pemindaian mental manusia. Contoh lain dari pemanfaatan sinyal Electroencephalography ialah mengklasifikasi kondisi mata.

Sebelumnya dalam pengklasifikasian kondisi mata ini, Oliver Roesler dkk. telah menerapkan metode-metode classifier untuk mengelompokkan kondisi mata berdasarkan sinyal EEG tersebut. Namun dari percobaan yang dilakukan oleh Roesler dkk., metode classifier yang bersifat probabilistik masih belum mencapai performansi yang optimal, yaitu angka galat masih melebihi 25% [10][12].

Pada dasarnya, klasifikasi bersifat probabilistik merupakan proses menentukan kelas dimana klasifikasi tersebut menggunakan penalaran berdasarkan teori probabilitas suatu kelas terhadap data ($P(y|X)$), yang kemudian kelas ditentukan dengan cara memilih kandidat kelas dengan probabilitas tertinggi. Penalaran bersifat probabilistik dinilai dapat menangani data yang bersifat tidak pasti [11].

David Barber memaparkan bahwa dalam disiplin ilmu machine learning, terdapat banyak metode-metode classifier yang bersifat probabilistik dan dapat dimodelkan dalam bentuk graf (graphical model), salah satunya yaitu Gaussian Process [7]. Sedangkan Carl Edward Rasmussen dalam buku ajarnya [6] berpendapat bahwa Gaussian Process merupakan bentuk generalisasi dari distribusi normal pada teori probabilitas dimana variabel acak tersebut merepresentasikan nilai skalar maupun vektor. Di samping itu Gaussian Process adalah salah satu bentuk Bayesian Networks yang fleksibel dengan studi kasus yang bersifat probabilistik.

Kelebihan dari classifier yang bersifat probabilistik ialah classifier ini mampu menghasilkan performansi yang tinggi walaupun iterasi yang diterapkan pada fase pelatihan cukup sedikit [8][13][14]. Pada penerapannya, metode Gaussian Process mampu menunjukkan performansi akurasi sebesar 80% untuk kasus Pima Indians Diabetes [3]. Disamping itu Gaussian Process juga menunjukkan performansi yang sangat baik untuk kasus CRAB, dimana performansi akurasinya mencapai 97.5% [2].

Dengan melihat performansi pada data-data sebelumnya, pada Tugas Akhir ini diterapkan Gaussian Process sebagai metode klasifikasi. Metode klasifikasi ini diterapkan terhadap data kondisi mata berdasarkan sinyal Electroencephalography sebagai alternatif dari classifier-classifier probabilistik yang telah diteliti oleh Roesler dkk. sebelumnya. Selain itu pada Tugas Akhir ini juga ditentukan parameter yang tepat untuk mengetahui performansi tertinggi pada Gaussian Process. Penerapan metode ini tergolong inovatif, dikarenakan belum ada penelitian yang menerapkan Gaussian Process untuk menggolongkan kondisi mata yang serupa.

Topik dan Batasannya

Dengan melihat latar belakang sebelumnya maka dirumuskan dua rumusan masalah. Pertama, Bagaimana merancang sistem classifier yang mampu mengolah sinyal Electroencephalography untuk mendeteksi kondisi mata dengan menggunakan parameter-parameter yang tepat? Dan jika sistem classifier sudah terancang, Bagaimana menganalisis performansi dari sistem yang telah dibangun berdasarkan akurasi dan waktu komputasi?

Kemudian, agar penyelesaian masalah lebih terarah, maka perlu ditentukan batasan-batasan masalah. Batasan-batasan tersebut ialah: algoritma classifier yang digunakan adalah Gaussian Process, dan data yang digunakan adalah data kondisi mata berdasarkan sinyal electroencephalography yang merujuk pada laman situs web http://suendermann.com/corpus/EEG_Eyes.arff.gz.

Tujuan

Setidaknya ada dua tujuan dari artikel ini. Pertama adalah untuk merancang sistem classifier yang mampu mengolah sinyal EEG untuk mendeteksi kondisi mata menggunakan metode Gaussian Process dengan menggunakan parameter-parameter yang tepat. Parameter-parameter tersebut meliputi pemilihan model, fungsi kovarian yang digunakan, dan jumlah iterasi Newton yang semuanya diterapkan pada classifier Gaussian Process. Dan yang kedua, artikel ini menganalisis performansi dari sistem classifier Gaussian Process yang telah dibangun berdasarkan akurasi dan waktu komputasi.

Organisasi Tulisan

Setelah dipaparkan pendahuluan, pada artikel ini dijelaskan beberapa hal yang terkait terhadap klasifikasi keadaan mata beserta metode classifiernya. Kemudian dijelaskan pula sistem yang dibangun yang meliputi himpunan data, alur kerja classifier secara umum, beserta parameter-parameter performansi yang dipakai. Pada sub-bab evaluasi, artikel ini memaparkan hasil pengujian beserta analisisnya. Setelah dievaluasi, pada artikel ini ditarik beberapa kesimpulan berdasarkan evaluasi yang telah dilakukan.

2. Studi Terkait

Electroencephalography (EEG)

Menurut Ernst Neidermeyer, Electroencephalography (EEG) merupakan suatu teknik pencitraan yang membaca sinyal yang dihasilkan oleh otak dimana sinyal tersebut ditangkap oleh elektroda logam dan media konduktif [5]. Otak manusia sebenarnya memancarkan sinyal elektromagnetik yang dapat ditangkap oleh sensor yang dirancang khusus. Kemudian sinyal yang telah ditangkap diperkuat amplitudonya menggunakan amplifier. Setelah sinyal diperkuat kemudian sinyal mengalami proses filtering. Dan pada akhirnya sinyal yang semula analog dikonversi menjadi sinyal digital.

Ketika penelitian terhadap EEG mulai dicetuskan, sebenarnya hal tersebut bisa dikembangkan lebih jauh. Sinyal EEG dapat dipetakan menjadi topografi-topografi yang dapat ditangkap sinyalnya secara waktu nyata. Dengan mengetahui hal tersebut, maka sebenarnya sensor pada sinyal EEG dapat didesain menjadi 16 kanal atau lebih, disertai dengan dukungan perangkat keras yang mutakhir [1].

Brain-computer Interface

Dengan menerapkan konsep dasar electroencephalography, maka muncullah konsep Brain Computer Interface (BCI) dimana otak berinteraksi dengan perangkat eksternal. BCI menggunakan gelombang otak untuk melakukan suatu tindakan tertentu yang berhubungkan dengan perangkat yang terhubung.

Ketika perangkat BCI membaca sinyal otak, terdapat noise yang mengurangi akurasi aksi kerja BCI, sehingga terdapat banyak fitur (yang didapat dari sensor kanal) yang perlu diekstraksi. Sinyal otak yang ditangkap oleh sensor direpresentasikan oleh fitur-fitur yang kemudian diklasifikasikan menggunakan metode klasifikasi [9].

Jonathan R. Wolpaw dkk. menegaskan bahwa perangkat antarmuka komputer-otak memungkinkan manusia untuk berkomunikasi maupun mengendalikan perangkat sekitar tanpa harus menggerakkan anggota badan. Dengan kata lain otot tidak terlibat aktif ketika perangkat bekerja, melainkan aktivitas elektro-psikologis yang ditampilkan dengan sinyal electroencephalography ataupun dengan aktivitas otak lainnya. Perangkat interaksi komputer-otak bekerja bergantung pada dua controller, yaitu pengguna aktif perangkat dan perangkat itu sendiri yang aktif membaca aktivitas otak pengguna [4].

Klasifikasi Kondisi Mata berdasarkan Sinyal EEG

Ruang lingkup penelitian terhadap Electroencephalography (EEG) yang luas, salah satunya berfokus pada kondisi mata, dimana mata terbuka dan tertutup (eye-state) dapat diklasifikasikan dengan melihat aktivitas sinyal otak yang ditangkap oleh perangkat BCI yang dinamakan Emotiv EPOC.


Dengan tersedianya data, Oliver Roesler dkk. telah menerapkan 42 metode klasifikasi baik yang bersifat geometris, probabilistik, maupun berbasis aturan untuk mengklasifikasi data. Dan ketika telah analisis, Olivier Roesler dkk. menyajikan grafik, dimana dapat disimpulkan metode klasifikasi yang bersifat probabilistik memiliki angka kesalahan paling tinggi, diikuti dengan klasifikasi yang berbasis aturan, dan klasifikasi yang bersifat geometris memiliki angka error paling minimum. Namun sayangnya, perbandingan metode-metode tersebut belum bersifat user-independent, sehingga menghasilkan nilai-nilai yang cenderung subjektif [10].

Dikarenakan perlu perbandingan yang setara terhadap klasifikasi eye-state, maka Roesler dkk. melakukan perbandingan antara Emotiv EPOC dengan perangkat lainnya, salah satunya ialah BrainAmp. Pada sejumlah data yang dihasilkan oleh masing-masing perangkat, data tersebut diolah dengan 83 algoritma klasifikasi yang berbeda [12]. Perlu diketahui sebelumnya, EPOC menggunakan 14 dari 16 kanal sedangkan BrainAmp memiliki 32 kanal, meskipun pada saat percobaan hanya 14 kanal yang digunakan. Selain itu apabila dibandingkan menggunakan 83 algoritma klasifikasi, maka sebagian besar error yang dihasilkan apabila menggunakan BrainAmp terlihat lebih kecil dibandingkan dengan Epoc, sehingga BrainAmp dinilai memiliki performansi yang lebih baik. Namun, performansi yang dihasilkan oleh EPOC terlihat menjanjikan, dikarenakan ada beberapa metode classifier menghasilkan error rate yang lebih rendah apabila menggunakan EPOC daripada BrainAmp [12].

Klasifikasi menggunakan Gaussian Process

Menurut Carl Edward Rasmussen [6], Gaussian Process merupakan bentuk generalisasi dari distribusi normal pada teori probabilitas dimana variabel acak tersebut merepresntasikan nilai skalar maupun vektor. Sedangkan David Barber pada buku ajarnya [7], menyatakan bahwa Gaussian Process adalah salah satu bentuk Bayesian Networks yang fleksibel dengan studi kasus yang bersifat probabilistik.

Ide utama dari klasifikasi menggunakan Gaussian Process adalah dengan menempatkan variabel acak tersebut f yang mendapat pengaruh dari variabel acak x untuk memberikan pengaruh terhadap variabel acak y sebagai label kelasnya. Gambar 2.4 menjelaskan tentang hubungan antar variabel acak dimana variabel baru f* mendapat pengaruh dari f lama, kumpulan dari variabel x¹ hingga x^N, dan variabel baru x*. Sedangkan setiap variabel f mendapat pengaruh dari setiap variabel x dan setiap variabel y



Gambar 1. Bentuk model grafik probabilistik dari klasifikasi menggunakan Gaussian Process [7].

Dengan melihat Gambar 1 beserta pemaparan sebelumnya, maka ditentukan persamaan probabilitas posterior (1) sebagai berikut.

$$p(f^*, f|X, y, x^*) \propto p(f^*, f, y|x^*, X) \propto p(f^* |X, x^*, f)p(f|X, y) \tag{1}$$

Sedangkan probabilitas p(f|X, y) dapat dijabarkan dengan persamaan (2) sebagai berikut.

$$p(f|X, y) \propto \left\{ \prod_{n=1}^Y P(y^n|f^n) \right\} p(f^1, \dots, f^N |x^1, \dots, x^N) \tag{2}$$

Pada persamaan (2), $\prod_{n=1}^N p(y^n|f^n)$ berfungsi sebagai class mapping dan $p(f^1, \dots, f^N | x^1, \dots, x^N)$ berfungsi sebagai Gaussian Process.

Merujuk pada buku ajar Rasmussen [6], probabilitas $p(f|X, y)$ dilakukan aproksimasi atau pendekatan Gaussian $q(f|X, y)$ menggunakan metode Laplace. Sehingga dengan melakukan menjabarkan deret Taylor tingkat dua, maka dirumuskan persamaan berikut.

$$q(f|X, y) = N(f|\hat{f}, A^{-1}) \propto \exp(-\frac{1}{2}(f - \hat{f})^T A (f - \hat{f})) \tag{3}$$

pada persamaan (3), \hat{f} merupakan variabel acak tersembunyi f yang telah menemukan titik maksimumnya melalui penalaran, dimana $\hat{f} = \text{argmax}_f p(f|X, y)$ sedangkan $A = -\nabla\nabla \log p(f|X, y)|_{f=\hat{f}}$ merupakan log posterior negatif pada titik tersebut.

Penalaran

Untuk mendapatkan nilai \hat{f} maka yang perlu dilakukan adalah mencari nilai maksimum dari persamaan

$$p(f|y) \propto p(f, y) = \exp(\Psi(f)) \tag{4}$$

dimana

$$\Psi(f) = \log p(y|f) - \frac{1}{2}f^T K(X, X)^{-1}f - \frac{1}{2} \log |K(X, X)| - \frac{n}{2} \log 2\pi \tag{5}$$

dimana $K(X, X)$ merupakan fungsi kovarian antar sesama matriks training X . Dengan melakukan penurunan persamaan (5) terhadap f maka ditentukan

$$\nabla\Psi(f) = \nabla \log p(y|f) - K(X, X)^{-1}f \tag{6}$$

sedangkan turunan keduanya ialah

$$\begin{aligned} \nabla\nabla\Psi(f) &= \nabla\nabla \log p(y|f) - K(X, X)^{-1} \\ &= -W - K(X, X)^{-1} \end{aligned} \tag{7}$$

Dengan mengetahui turunan pertama dan kedua, maka pencarian nilai maksimum f dapat dilakukan dengan melakukan iterasi Newton, sehingga ditentukan persamaan sebagai berikut.

$$\begin{aligned} f^{\text{baru}} &= f - \nabla\nabla\Psi(f)^{-1} \nabla\Psi(f) \\ &= f + (K(X, X)^{-1} + W)^{-1} (\nabla \log p(y|f) - K(X, X)^{-1}f) \\ &= (K(X, X)^{-1} + W)^{-1} (Wf + \nabla \log p(y|f)) \end{aligned} \tag{8}$$

Iterasi Newton yang dipaparkan sebelumnya dilakukan dengan jumlah iterasi tertentu atau hingga variabel acak tersembunyi f termarginalisasi dengan baik. Ukuran baik tidaknya marjinalisasi atas variabel acak tersembunyi f tersebut diukur dengan konvergensi atas logaritma dari marginal likelihood (log marginal likelihood)

$$\log q(f|X) = -\frac{1}{2}\hat{f}^T K^{-1} + \log p(y|\hat{f}) - \frac{1}{2} \log |B| \tag{9}$$

dimana $|B| = |K(X, X)| \cdot |K(X, X)^{-1} + W|$.

Prediksi

Untuk memprediksi kelas di antara himpunan $\{-1, +1\}$, pada awalnya digunakan rata-rata prediktif Gaussian Process

$$E_q[f * |X, y, x^*] = K(X, X^*)^T K(X, X)^{-1} \hat{f} = K(X, x^*)^T \nabla \log p(y | \hat{f}) \tag{10}$$

dimana $K(X, x^*)$ merupakan fungsi kovarian antara matriks training X dengan matriks testing x^* . Namun, rata-rata prediktif di atas menghasilkan nilai real sehingga dilakukan pembatasan sebagai berikut.

$$\text{prediksi} = \begin{cases} +1, & \text{jika } E_q[f * |X, y, x^*] > 0 \\ -1, & \text{lainnya} \end{cases} \tag{11}$$

Fungsi Kovarian

Fungsi kovarian merupakan fungsi yang membentuk matriks positif definit, dimana setiap elemennya terbentuk dari $k(x, x^*)$ [7]. Jika diketahui terdapat terdapat matriks X yang memiliki elemen x^1, x^2, \dots, x^N dan matriks Y yang memiliki elemen y^1, y^2, \dots, y^M , maka fungsi kovarian $K(X, Y)$ membentuk matriks dengan ukuran $N \times M$. Selain itu, pada classifier Gaussian Process, fungsi kovarian berfungsi sebagai fungsi prior.

Dengan menggunakan definisi $r = \|x - x^*\|$, maka fungsi-fungsi kovarian yang digunakan dalam Tugas Akhir ini adalah sebagai berikut.

Tabel 1. Fungsi-fungsi kovarian.

Nama Fungsi	Persamaan	Keterangan
Radial Basis Function (RBF)	$k(x, x^*) = e^{-\frac{1}{2}r}$	
Matérn	$k(x, x^*) = \frac{1}{2^{\nu-1}\Gamma(\nu)} \left(\frac{\sqrt{2\nu}r}{\rho}\right)^{\nu} K_{\nu}\left(\frac{\sqrt{2\nu}r}{\rho}\right)$	$\nu = \frac{3}{2}$ atau $\nu = \frac{5}{2}; \rho = 1$

3. Sistem yang Dibangun

Himpunan data

Pada perancangan sistem ini, himpunan data keadaan mata dan sinyal electroencephalography diperoleh dari alamat web http://suendermann.com/corpus/EEG_Eyes.arff.gz. Kemudian, data tersebut dilakukan pra pemrosesan dengan beberapa langkah.

Sistem melakukan eliminasi terhadap setiap baris data yang salah satu fiturnya (atau lebih) memiliki nilai di luar batas-batas yang telah ditentukan oleh Rösler sesuai dengan tabel 1 [10]. Untuk memenuhi syarat pemrosesan klasifikasi menggunakan Gaussian Process, maka himpunan kelas $\{0, 1\}$ diubah menjadi $\{-1, 1\}$. Kemudian urutan data tersebut diacak sebanyak 30 kali. Hal ini dilakukan untuk memastikan semua kelas 1 dan -1 terdistribusi dengan baik.

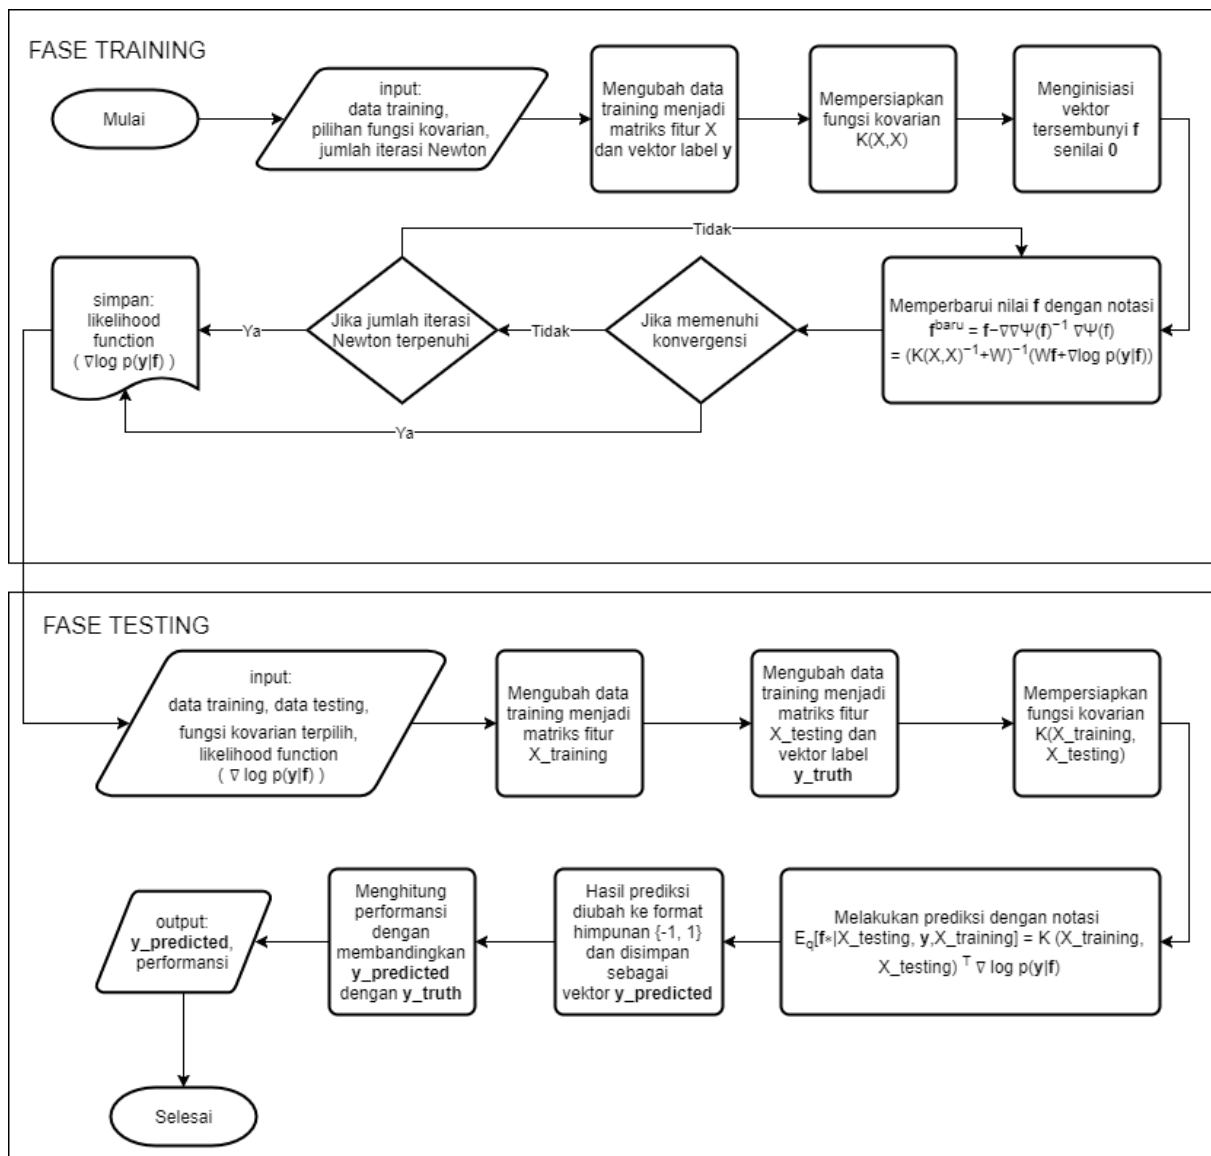
Tabel 2. Batas-batas pada setiap nilai fitur

Fitur	class 1		class 0	
	min	max	min	max
AF3	4198	4445	1030	4504
F7	3905	4138	3924	7801
F3	4212	4367	4197	5762
FC5	4058	4214	2453	4250
T7	4309	4435	2089	4463
P7	4574	4708	2768	4756
O1	4026	4167	3581	4178
O2	4567	4695	4567	7264
P8	4147	4287	4152	4586
T8	4174	4323	4152	6674
FC6	4130	4319	4100	5170
F4	4225	4368	4201	7002
F8	4510	4811	86	4833
AF4	4246	4552	1366	4573

Dengan teracaknya urutan data, untuk tujuan pemilihan model klasifikasi, maka data dipecah dengan kaidah K-fold Cross Validation. K-fold Cross Validation merupakan teknik pemilihan model klasifikasi dimana data dipecah menjadi k bagian, kemudian salah satu (atau lebih, selama tidak sejumlah k) diambil sebagai data testing, sedangkan lainnya digunakan sebagai data training.

Pada pemrosesan baik dalam fase training maupun testing, semua fitur pada seluruh baris data direpresentasikan sebagai matriks, sedangkan seluruh kelas pada setiap baris data training maupun prediksi direpresentasikan sebagai vektor.

Alur Kerja Sistem



Gambar 2. Diagram alir secara umum

Berdasarkan bagan yang dipaparkan pada Gambar 2, sistem menerima beberapa input, yaitu data training, fungsi kovarian yang terpilih berdasarkan Tabel 1, dan jumlah iterasi Newton yang diinginkan. Selanjutnya, data training diubah menjadi matriks fitur X dan vektor label y. Kemudian fungsi kovarian dipersiapkan dengan notasi $K(X, X)$. Kemudian, dilakukanlah iterasi Newton dengan menerapkan persamaan (8). Setelah satu iterasi diterapkan maka dihitung log marginal likelihood. Pada iterasi ini terdapat dua titik henti, yaitu apabila log marginal likelihood konvergen atau nilai maksimum iterasi terpenuhi. Setelah iterasi selesai, maka sistem menyimpan likelihood function.

Sistem menerima inputan berupa data training, data testing, beserta likelihood function yang telah dikalkulasi sebelumnya. Setelah itu, data training diubah menjadi matriks fitur $X_{training}$, sedangkan data testing diubah menjadi matriks fitur $X_{testing}$ dan vektor label y_{truth} . Kemudian fungsi kovarian dipersiapkan dengan notasi $K(X_{training}, X_{testing})$. Selanjutnya, dengan menerapkan persamaan (10), persamaan untuk melakukan prediksi dinotasikan sebagai berikut.

$$E_q[f * | X_{training}, y, X_{testing}] = K(X_{training}, X_{testing})^T \nabla \log p(y | \hat{f}) \tag{12}$$

Setelah itu hasil prediksi diubah sesuai dengan himpunan kelas $\{-1, 1\}$ dengan menerapkan persamaan (11) dan disimpan sebagai vektor $y_{predicted}$. Kemudian, $y_{predicted}$ dan y_{truth} digunakan untuk perhitungan performansi. Dan pada akhirnya sistem akan menghasilkan hasil prediksi ($y_{predicted}$) beserta performansinya.

4. Evaluasi

Setelah sistem dirancang, maka dilakukan pengujian dengan parameter-parameter tertentu. Pada artikel ini, f1-score menjadi acuan performansi, karena selain merupakan gold standard, pada dasarnya f1-score merupakan rata-rata harmonik dari presisi dan recall. Selain itu pada performansi Gaussian Process berdasarkan nilai k pada K-fold Cross Validation dipaparkan dengan menampilkan nilai minimum, rata-rata, dan nilai maksimum pada masing-masing pengukuran, serta dibandingkan dengan performansi Regresi Logistik. Hasil pengujian beserta analisisnya dipaparkan sebagai berikut.

Hasil Pengujian

Hasil pengujian berdasarkan nilai k pada K-fold Cross Validation dijelaskan pada Tabel 3. Pada artikel ini, jumlah k yang ditentukan sebagai parameter adalah $k = 5$ dan $k = 10$. Sebagai perbandingan, dipaparkan pula hasil pengujian berdasarkan nilai k pada K-fold Cross Validation dengan menggunakan Regresi Logistik pada tabel 4. Pada penelitian ini pula diterapkan iterasi Newton masing-masing sejumlah 1, 2, 5, 10, 20, 50, 100, dan 200. Tabel 5 memaparkan pengaruh jumlah iterasi Newton terhadap performansi Gaussian Process.

Tabel 3. Performansi Gaussian Process berdasarkan nilai k pada K-fold Cross Validation

k	Akurasi			Presisi			Recall			F1-Score		
	min	mean	max	min	mean	max	min	mean	max	min	mean	max
5	0.97527	0.97765	0.98162	0.96680	0.97433	0.98238	0.96379	0.97589	0.98047	0.97243	0.97508	0.97993
10	0.97193	0.98028	0.98663	0.96481	0.97778	0.98341	0.97189	0.97827	0.98849	0.96903	0.97802	0.98565

Tabel 4. Performansi Regresi Logistik berdasarkan nilai k pada K-fold Cross Validation

k	Akurasi			Presisi			Recall			F1-Score		
	min	mean	max	min	mean	max	min	mean	max	min	mean	max
5	0.63168	0.63982	0.65174	0.58899	0.63056	0.64971	0.43910	0.47963	0.50156	0.52212	0.54401	0.56034
10	0.62233	0.64196	0.66778	0.58776	0.63220	0.67059	0.44444	0.48231	0.51520	0.50615	0.54713	0.57702

Tabel 5. Performansi Gaussian Process berdasarkan iterasi Newton

Jumlah Iterasi	Akurasi	Presisi	Recall	F1-Score	Durasi Training
1	0.98663	0.98283	0.98849	0.98565	0 jam, 3 menit, 4.715 detik
2	0.98663	0.98283	0.98849	0.98565	0 jam, 7 menit, 28.120 detik
5	0.98663	0.98283	0.98849	0.98565	0 jam, 20 menit, 37.677 detik
10	0.98663	0.98283	0.98849	0.98565	0 jam, 23 menit, 26.601 detik
20	0.98663	0.98283	0.98849	0.98565	0 jam, 22 menit, 24.566 detik
50	0.98663	0.98283	0.98849	0.98565	0 jam, 21 menit, 52.773 detik
100	0.98663	0.98283	0.98849	0.98565	0 jam, 28 menit, 6.808 detik
200	0.98663	0.98283	0.98849	0.98565	0 jam, 23 menit, 48.200 detik

Tabel 6 berikut menjelaskan pengaruh fungsi kovarian terhadap performansi Gaussian Process dimana pada artikel ini diterapkan RBF dan Matérn sebagai fungsi kovarian.

Tabel 6. Performansi Gaussian Process berdasarkan fungsi kovarian

Fungsi Kovarian	Akurasi	Presisi	Recall	F1-Score	Durasi Training
RBF	0.98463	0.98138	0.98561	0.98349	0 jam, 12 menit, 13.648 detik
Matérn ($\nu = 3/2$)	0.98663	0.98283	0.98849	0.98565	0 jam, 20 menit, 37.677 detik
Matérn ($\nu = 5/2$)	0.98596	0.98143	0.98849	0.98495	0 jam, 22 menit, 54.917 detik

Berbagai pelatihan dan pengujian model ini diterapkan pada sebuah komputer pribadi yang menggunakan Intel® Core™ i7-3770 sebagai processor dengan clock speed senilai 3.40 GHz pada masing-masing core-nya, dan RAM DDR3 PC-12800 sejumlah 8GB. Selain itu pada fase training, program classifier menggunakan seluruh core dan menyisakan satu core pada processor.

Analisis Hasil Pengujian

Dengan memperhatikan pengujian sebelumnya, maka ditentukan beberapa analisis. Pertama-tama, dengan mengacu pada kolom F1-Score pada Tabel 3, terlihat bahwa $k = 10$ memiliki nilai F1-Score yang lebih tinggi dari $k = 5$. Hal ini sesuai dengan konsep dasar pengklasifikasian bahwa semakin besar jumlah sampel pada data training, maka semakin maksimal performansi yang dihasilkan pada fase testing.

Di samping itu pada penelitian ini dilakukan perbandingan performansi Gaussian Process dengan Regresi Logistik berdasarkan nilai k pada K-fold, dimana Regresi Logistik merupakan metode klasifikasi dasar. Apabila dibandingkan antara Tabel 3 dengan Tabel 4, Gaussian Process memiliki F1-Score lebih tinggi dengan nilai 97.802% pada $k = 10$, dibandingkan dengan Regresi Logistik dengan nilai 54.713% pada $k = 10$. Pada akhirnya dapat diketahui bahwa performansi Gaussian Process lebih baik dari Regresi Logistik

Pada tabel 5, terlihat tidak ada perubahan performansi setelah iterasi pertama. Hal ini dikarenakan pada iterasi pertama proses training pada Gaussian Process sudah mencapai log marginal likelihood yang optimal. Hal menguatkan Gaussian Process sebagai classifier yang bersifat deterministik, sehingga proses pemodelan terhadap data bersifat tetap dan tidak perlu melakukan pemodelan ulang untuk memastikan performansinya. Dan pada akhirnya, untuk melakukan training terhadap data keadaan mata berdasarkan sinyal EEG, maka classifier Gaussian Process cukup melakukan satu kali iterasi Newton.

Seperti yang dipaparkan pada Tabel 6, Model Gaussian Process dengan fungsi kovarian Matérn dengan $\nu = \frac{3}{2}$ memiliki performansi lebih baik dibandingkan dengan fungsi kovarian RBF dan Matérn dengan $\nu = \frac{5}{2}$ apabila mengacu pada nilai F1-Score. Perlu diketahui, ketiga skenario fungsi kovarian tersebut sama-sama bersifat stationary, dimana fungsi tersebut sama-sama melibatkan definisi $r = ||x - x^* ||$. Mengacu pada Tabel 5, fungsi kovarian yang bersifat stationary dinilai sangat sesuai dengan data keadaan mata berdasarkan sinyal EEG. Selain itu pada fungsi kovarian Matérn penerapan $\nu = \frac{3}{2}$ (pada buku teks Rasmussen [6], variable ν yang cocok untuk machine learning ialah $\nu = \frac{3}{2}$ dan $\nu = \frac{5}{2}$) sangat tepat dan memiliki performansi yang lebih baik dari RBF.

5. Kesimpulan

Setelah melakukan beberapa evaluasi dan analisis maka ada beberapa hal yang disimpulkan. Pertama-tama Gaussian Process mampu berperformansi lebih baik (apabila dibandingkan dengan Regresi Logistik sebagai classifier dasar) dengan performansi tertingginya dimana classifier Gaussian Process telah mencapai akurasi sejumlah 98.663%, presisi 98.283%, recall 98.849%, dan f1-score senilai 98.565% terhadap data keadaan mata berdasarkan sinyal EEG, dengan menggunakan Matérn dengan nilai $\nu = \frac{3}{2}$ sebagai fungsi kovarian, perbandingan data testing dan data training sejumlah 1:9, dan satu kali iterasi Newton.

Selain itu, Gaussian Process merupakan classifier yang bersifat probabilistik yang mampu memberikan performansi terhadap data keadaan mata berdasarkan sinyal EEG. Hal ini dinilai mampu memperbaiki penelitian yang dilakukan oleh Oliver Rösler dkk. dimana akurasi pada classifier-classifier probabilistik masih mencapai 75% [10][12]. Dan pada akhirnya, classifier Gaussian Process mampu mendeteksi kondisi mata dengan sangat baik.

Namun ada beberapa hal yang perlu dicatat dalam penyusunan artikel ini. Pertama setiap fase training ini menempuh waktu yang cukup panjang. Hal ini dikarenakan setiap fitur pada data memiliki rentang nilai yang panjang antara 86 hingga 7801. Alangkah baiknya untuk penelitian ke depan diterapkan normalisasi yaitu dengan mengkonversi nilai-nilai untuk setiap fitur menjadi rentang 0 hingga 1 untuk mempermudah proses komputasi pada classifier dan diharapkan dapat mempersingkat waktu training.

Meskipun K-fold Cross Validation diterapkan sebagai pemilihan model pada penelitian ini, namun kemungkinan overfitted pada model-model yang telah terbentuk tergolong tinggi, mengingat iterasi-iterasi awal model Gaussian Process sudah mencapai performansi terbaik. Maka dari itu untuk penelitian ke depan sangat disarankan untuk melakukan cara lain untuk memastikan model classifier agar tidak overfitted, salah satunya ialah dengan melakukan optimasi terhadap hyperparameter pada fungsi kovarian maupun fungsi likelihood.

Ucapan Terimakasih

Aditya Mahesa mengucapkan terimakasih kepada Allah, Tuhan Yang Maha Esa, yang kasih-Nya tak terbilang. Mahesa selaku penyusun juga mengucapkan terimakasih kepada kedua orang tua, kakak-kakak dan adik, serta rekan-rekan yang telah memberikan support baik moril mau materiil sehingga artikel ini dapat disusun dengan baik. Rasa hormat dan terimakasih yang setinggi-tingginya penyusun sampaikan kepada Ibu Untari Novia Wisesty selaku Pembimbing 1 Tugas Akhir dan Bapak Adiwijaya selaku Pembimbing 2 yang telah memberikan arahan dalam penyusunan artikel ini sebaik-baiknya.

Daftar Pustaka

- [1] I. Rampil, "Elements of EEG signal processing", International journal of clinical monitoring and computing, vol. 4, no. 2, pp. 85–98, 1987.
- [2] M. N. Gibbs, "Bayesian Gaussian processes for regression and classification", PhD thesis, University of Cambridge Cambridge, England, 1998.

- [3] C. K. Williams and D. Barber, "Bayesian classification with Gaussian processes", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 20, no. 12, pp. 1342–1351, 1998.
- [4] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain–computer interfaces for communication and control", *Clinical neurophysiology*, vol. 113, no. 6, pp. 767–791, 2002.
- [5] E. Niedermeyer and F. L. da Silva, *Electroencephalography: basic principles, clinical applications, and related fields*. Lippincott Williams & Wilkins, 2005.
- [6] C. E. Rasmussen and C. K. I. Williams, *Gaussian processes for machine learning*. MIT Press, 2006.
- [7] D. Barber, *Bayesian reasoning and machine learning*. Cambridge University Press, 2012.
- [8] U. N. Wisesty, T. H. Liong, et al., "Indonesian speech recognition system using Discriminant Feature Extraction—Neural Predictive Coding (DFE-NPC) and Probabilistic Neural Network", in *Computational Intelligence and Cybernetics (CyberneticsCom)*, 2012 IEEE International Conference on, IEEE, 2012, pp. 158–162.
- [9] R. Kottaimalai, M. P. Rajasekaran, V. Selvam, and B. Kannapiran, "EEG signal classification using principal component analysis with neural network in brain computer interface applications", in *Emerging Trends in Computing, Communication and Nanotechnology (ICE-CCN)*, 2013 International Conference on, IEEE, 2013, pp. 227–231.
- [10] O. Rösler and D. Suendermann, "A first step towards eye state prediction using eeg", *Proc. of the AIHLS*, 2013.
- [11] J. Pearl, *Probabilistic reasoning in intelligent systems: networks of plausible inference*. Morgan Kaufmann, 2014.
- [12] O. Roesler, L. Bader, J. Forster, Y. Hayashi, S. Heßler, and D. Suendermann-Oeft, "Comparison of EEG Devices for Eye State Classification", *Proc. of the AIHLS*, 2014.
- [13] U. N. Wisesty, W. Astuti, et al., "Feature extraction analysis on Indonesian speech recognition system", in *Information and Communication Technology (ICoICT)*, 2015 3rd International Conference on, IEEE, 2015, pp. 54–58.
- [14] U. N. Wisesty, M. S. Mubarak, and Adiwijaya, "A classification of marked hijaiyah letters' pronunciation using hidden Markov model", in *AIP Conference Proceedings*, AIP Publishing, vol. 1867, 2017, p. 020036.