

Deteksi Gestur Lengan Dinamis pada Lingkungan Virtual Tiga Dimensi Koleksi Warisan Budaya

Adri Gabriel Sooi^{1,2}, Atyanta. N. Rumaksari³, Khamid¹, Nurul Zainal Fanani¹,
Surya Sumpeno⁴, Mauridhi Hery Purnomo⁴

Abstract— Virtual reality technology can be used to support museum exhibitions. Implementation could be in various platforms. There are many implementation options, for example in smartphones, tablet, and desktop computers. Most objects of museum collections are very fragile. Minimizing the direct touch on a collection object is one of the benefits of this technology. This study aims to prepare gestures suitable for the exploration of virtual objects of cultural heritage collection. Five sets of gestures have been prepared, namely lifting, picking, holding, sweeping from both directions, left and right. Dynamic arm gestures are recorded using the forearm sensor. The recorded data contains coordinates of gestures in form of x , y , z , raw , $pitch$, and yaw . Gaussian mixture models are used in selecting features to produce good accuracy in the classification process. Two functions are used, namely probability density function and cumulative distribution function for the feature selection process. In this study, two experiments were used to train the gesture model. The accuracy of the two experiments is shown in the form of a confusion matrix. Each of the confusion matrices show excellent results of 99.8% for SVM and k -NN. Furthermore, modeling results are tested using new data. The testing shows 89.25% result for SVM classifier and 90.09% for k -NN. Four other dynamic arm gestures have a very satisfactory rate of 100% for the two classifiers. The five gestures can be used in the development of virtual reality applications.

Intisari— Teknologi *virtual reality* dapat digunakan untuk mendukung pameran museum. Implementasinya dapat menggunakan berbagai platform. Tersedia banyak pilihan implementasi, contohnya telepon pintar, komputer tablet, maupun komputer desktop. Kebanyakan benda koleksi museum sangat rapuh. Meminimalkan sentuhan langsung pada benda koleksi merupakan salah satu manfaat teknologi ini. Makalah ini bertujuan untuk menyiapkan gestur yang cocok untuk eksplorasi benda virtual koleksi warisan budaya. Telah disiapkan lima gestur lengan, yaitu: mengangkat, memungut, memegang, menyapu dari dua arah, kiri dan kanan. Gestur lengan dinamis direkam menggunakan sensor lengan bawah.

¹Mahasiswa, Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, Surabaya, Jawa Timur, INDONESIA, 60111 (e-mail: adri14@mhs.ee.its.ac.id, perumsat@gmail.com, fanani.tkk@gmail.com)

²Dosen, Teknik Informatika, Universitas Katolik Widya Mandira, Jln. A.Yani No. 50-52 Kupang, NTT, INDONESIA 85225 (e-mail: adrigabriel@gmail.com)

³Dosen, Universitas Kristen Satya Wacana Salatiga Jl. Diponegoro 52-60 Salatiga - INDONESIA 50711 (e-mail: atyanta.nika@gmail.com)

⁴Dosen, Departemen Teknik Elektro dan Departemen Teknik Komputer, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, Surabaya, Jawa Timur, INDONESIA 60111 (e-mail: surya@ee.its.ac.id, hery@ee.its.ac.id)

Hasil rekaman berupa koordinat x , y , z , raw , $pitch$, dan yaw . Dilakukan prediksi data awal menggunakan *Gaussian Mixture Model*. Untuk menentukan pengklasifikasi yang terbaik, dapat digunakan *probability density function* dan *cumulative distribution function*. Dalam makalah ini, digunakan dua percobaan untuk melatih model gestur. Ketepatan dari kedua percobaan ditampilkan dalam bentuk *confusion matrix*. Masing-masing *confusion matrix* menunjukkan hasil yang sangat baik, yaitu 99,8% untuk SVM dan k -NN. Selanjutnya, hasil pemodelan diuji menggunakan data baru. Pengujian menunjukkan hasil sebesar 89,25% untuk pengklasifikasi SVM dan 90,09% untuk k -NN. Empat gestur lengan dinamis lainnya memperoleh angka yang sangat memuaskan yaitu sebesar 100% untuk kedua pengklasifikasi. Kelima gestur dapat digunakan dalam pengembangan aplikasi *virtual reality*.

Kata Kunci— *Gaussian Mixture Model*, Gestur Lengan Dinamis, k -NN, Koleksi Warisan Budaya, *Virtual Reality*.

I. PENDAHULUAN

Museum sebagai salah satu tempat untuk melakukan proses belajar mulai kehilangan daya tariknya [1], [2]. Namun, ketertarikan belajar ke museum dapat ditingkatkan melalui berbagai cara. Salah satunya adalah dengan meningkatkan jumlah ekshibisi. Dalam kesempatan ekshibisi, museum dapat dilengkapi dengan teknologi *virtual reality* tiga dimensi [3], [4], yang akan membawa para pengunjung merasakan nuansa yang baru. Teknologi ini terbukti banyak digunakan oleh berbagai kalangan. Mempersiapkan teknologi *virtual reality* tiga dimensi untuk museum dapat dilakukan bertahap. Kegiatan awal dilakukan melalui pendataan terhadap artefak yang akan diikutkan dalam ekshibisi. Selanjutnya dilakukan kegiatan rekonstruksi ke dalam bentuk tiga dimensi virtual. Berbagai objek tiga dimensi virtual yang telah siap dapat dimasukkan ke dalam lingkungan virtual [5]. Penerapan langkah-langkah tersebut sudah banyak dikembangkan, tetapi tidak banyak yang memasukkan interaksi *immersive* di dalamnya [6]. Kegiatan dalam ruang virtual dapat meniru kegiatan di ruang nyata. Diharapkan interaksi dengan objek virtual seperti memegang, mengangkat, dan menggeser objek akan memberikan pengalaman khusus kepada para pengunjung ekshibisi. Bagi para generasi muda seperti pelajar dan mahasiswa, hal ini akan mampu menumbuhkan rasa ingin tahu yang lebih [7]–[9]. Sedangkan bagi para peneliti, kegiatan interaksi seperti memegang dan memutar benda dapat menjadi satu cara observasi yang menarik [10]. Mempersiapkan gerakan yang dapat digunakan dalam mengembangkan aplikasi dimaksud tentu harus dilakukan dengan teliti. Tidak semua gerakan dapat ditiru secara sama

persis. Hal ini diakibatkan oleh keterbatasan alat pengindra. Sebagai contoh, sensor *leapmotion* hanya memberikan data terperinci mengenai koordinat jari, telapak tangan, rotasi pergelangan tangan, dan kecepatan gerakan. Pemanfaatan peralatan sensor *leapmotion* untuk mendeteksi gestur lengan dinamis sudah dilakukan [11]. Namun, masih ditemukan kekurangan dalam membaca beberapa gestur. Hal ini terjadi pada saat sensor kamera inframerah terhalang tangan yang tumpang tindih dan pada gerakan telapak tangan yang berputar seratus delapan puluh derajat. Kekurangan lainnya yang terjadi adalah pada gerakan menyapu (menggerakkan telapak tangan ke kiri dan ke kanan). Akurasi yang diperoleh setelah melakukan pelatihan data untuk gerakan menyapu relatif rendah. Untuk menjawab kekurangan tersebut, makalah ini mencoba mengulang beberapa gerakan yang sama, tetapi menggunakan sensor yang berbeda, prediktor, dan pemilihan fitur berbantuan *Gaussian mixture model*. Selanjutnya, ditentukan gerakan yang dapat dipakai untuk mengembangkan aplikasi interaksi pada ruang virtual tiga dimensi dan melengkapi berbagai penelitian sebelumnya.

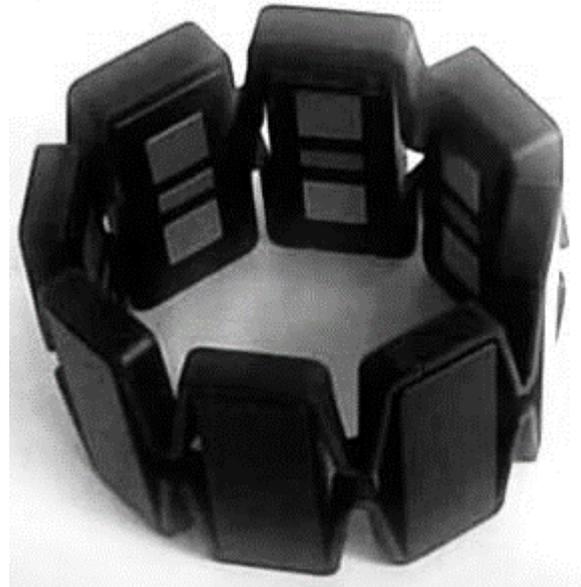
II. PENGENALAN GESTUR

Pengembangan aplikasi pendukung ekshibisi museum telah banyak dilakukan. Berbagai capaian penelitian tentang teknologi pendukung ekshibisi museum ini saling menunjang penelitian lanjutan. Tahapan pengembangannya dapat dimulai dari rekonstruksi benda ke dalam bentuk virtual tiga dimensi [12], [13], penempatan dalam ruang virtual, penentuan bentuk interaksi, penyajian pasif, dan penyajian aktif. Untuk lebih jelasnya, berikut adalah beberapa penelitian terkait yang dapat menjadi acuan, antara lain adalah *virtual reality* dengan penyajian pasif, gestur statis dan dinamis.

Aplikasi *virtual reality* yang dikembangkan untuk menunjang ekshibisi museum telah dilakukan oleh beberapa peneliti. Sebuah kombinasi sajian konten video dengan teknologi komputer grafis tiga dimensi memodelkan museum dengan apa adanya. Sajian tersebut dilengkapi dengan efek video dan audio [14], teks yang memiliki kesan kedalaman, narasi, dan latar belakang musik [15]. Peningkatan kualitas aplikasi *virtual reality* pasif dilanjutkan pengembangannya dengan hadirnya imitasi lokasi arkeologi yang berisi replika berbagai objek dalam sebuah situs purbakala. Hal ini dilakukan mengingat keterbatasan ruang untuk menampilkan semua benda peninggalan sejarah dalam ruangan museum [16]. Bentuk penyajian pasif dapat dilihat pada hasil penelitian dengan objek yang bervariasi [17], [18], sebagian tersebar pada pemanfaatan teknologi untuk mendukung ekshibisi museum, sebagian lagi untuk *game*, dan perencanaan ruang multiguna.

Pengenalan gestur statis telah dilakukan untuk beberapa kebutuhan seperti pengenalan bahasa isyarat [19]. Penelitian ini menggunakan metode menurunkan dimensi citra gestur menggunakan *non-negative matrix factorization*, dan selanjutnya melakukan klasifikasi menggunakan *compressive sensing*. Pendeteksian gestur statis ini menjadi dasar untuk penelitian selanjutnya pada gestur dinamis. Sebelum

munculnya sensor gestur dinamis jari-jemari tangan seperti *leapmotion*, pembacaan gestur juga telah dilakukan menggunakan metode *dynamic time warping* [20]. Sensor yang digunakan untuk pengukurannya adalah akselerometer, yang memberikan selisih waktu antara dua koordinat dan diukur menggunakan jarak Euclidean. Beberapa penelitian lainnya juga telah mencoba membaca gestur menggunakan berbagai sensor dan metode klasifikasi. Metode lainnya yang telah digunakan untuk melakukan pendeteksian gestur dinamis adalah *Hidden Conditional Neural Field (HCNF)* [21]. Tahapan pendeteksian yang dilakukan adalah ekstraksi fitur untuk meningkatkan akurasi, dilanjutkan dengan klasifikasi. Melalui tahapan ini hasil yang diperoleh untuk pengenalan gestur dinamis sebesar 89.5%.



Gbr. 1 Myo Armband.

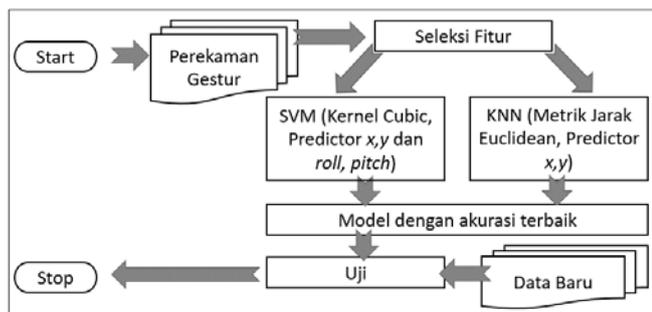
Pendeteksian gestur dinamis menggunakan Myo Armband seperti terlihat pada Gbr. 1 juga telah dilakukan untuk mengambil data gerakan olahraga [22]. Dalam penelitian tersebut terdapat tiga gestur, yaitu gerakan tangan saat memukul bola tenis, ketika melakukan gerakan servis, dan mengembalikan bola dari lawan secara *forehand* dan *backhand*. Gerakan-gerakan tersebut memiliki rentang koordinat x,y,z dan *raw, pitch, yaw* yang sangat lebar, dapat diukur menggunakan *Gaussian mixture model*. Pemanfaatan *Gaussian mixture model* dalam seleksi fitur membantu meningkatkan akurasi dalam proses klasifikasi untuk pendeteksian tiap gerakan.

Kombinasi dari dua sensor pendeteksi gestur jari dan lengan dilakukan untuk mendeteksi bahasa isyarat Indonesia [23]. Gestur dinamis yang diprediksi dalam penelitian ini adalah posisi jari, sudut, serta elevasi jari-jemari. Ketiga fitur tersebut diperoleh dari sensor *leapmotion*, sedangkan sensor Myo Armband membaca delapan kanal data *electromyograph (EMG)*, yaitu pembaca fungsi saraf otot. Kombinasi seluruh fitur ini kemudian diklasifikasikan menggunakan *naïve Bayes* untuk memperoleh model prediksi.

Hasil penelitian kombinasi dua sensor gestur tersebut mampu meningkatkan akurasi prediksi sebesar 7% yaitu dari 91% ke 98%. Kelemahan dari penelitian ini adalah tidak dipakainya data *orientation Euler* yang memiliki rentang pada kurva normal lebih besar dibandingkan data *electromyograph*.

III. METODE

Makalah ini menggunakan tahapan yang dimulai dengan penentuan gerakan lengan, pengambilan data, seleksi fitur menggunakan pemilihan *predictor* dan *Gaussian mixture model*.



Gbr. 2 Model proses yang diusulkan.

Keseluruhan proses pendeteksian gestur dinamis diawali dengan perekaman data. Perekaman data dilakukan menggunakan sepuluh orang anggota mahasiswa Laboratorium Komputasi Multimedia B401 Institut Teknologi Sepuluh Nopember Surabaya. Data yang direkam sebanyak dua kali, untuk data pelatihan dan untuk data pengujian. Peserta perekaman data tidak melakukan pengisian *consent form* sebab kegiatan penggunaan gelang sensor pada lengan tidak menimbulkan bahaya atau cedera bagi pemakainya. Hal ini didasarkan pada sertifikasi keamanan yang dimiliki oleh produk Myo Armband untuk digunakan pada pengguna berusia dua belas tahun ke atas.

Langkah berikutnya adalah pengolahan awal pada data. Data disebar pada salib sumbu koordinat Kartesius. Selanjutnya, melalui sebaran yang terlihat, dapat ditentukan *predictor* yang tepat. Pemilihan *predictor* yang tepat akan meningkatkan akurasi deteksi. Pilihan penentuan *predictor* lainnya adalah dengan menggunakan *Gaussian mixture model*, yang terbukti dapat memberikan masukan mengenai fitur yang terbaik untuk digunakan dalam proses klasifikasi [24]–[26]. Dalam proses klasifikasi, beberapa pengklasifikasi dapat digunakan untuk memperoleh akurasi dengan nilai tertinggi. Hal ini ditentukan oleh metrik jarak yang digunakan. Beberapa metrik jarak yang dapat dipakai antara lain adalah jarak Euclidean [27], jarak *cosine* [28] dan jarak Minkowski atau *cubic* [29].

Pemilihan pengklasifikasi bergantung pada karakteristik data. Untuk data dengan karakteristik yang berkumpul seperti citra tumor, maka *Support Vector Machine* (SVM) dan *k-Nearest Neighbor* (*k*-NN) dapat menjadi pilihan [30]. Beberapa besaran dalam penggunaan SVM sebagai pengklasifikasi antara lain adalah fungsi *kernel*, ukuran *kernel*, *box constrain level*, metode multi kelas, dan nilai Boolean untuk standardisasi data. Pengklasifikasi *k*-NN juga memiliki

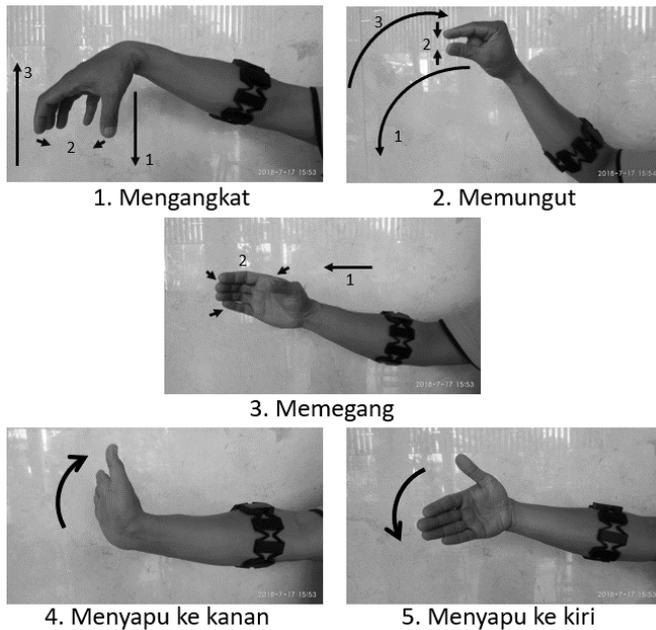
besaran, yaitu jumlah tetangga, pengukur jarak, bobot jarak dan nilai Boolean untuk standardisasi data. Kedua pengklasifikasi ini menghasilkan angka akurasi yang baik, berdasarkan seleksi fitur. Hal ini dimungkinkan melalui analisis yang telah dilakukan sebelumnya menggunakan pemilihan *predictor* dan *Gaussian mixture model*.

Selanjutnya, proses pengklasifikasian dilakukan sebanyak tiga percobaan. Percobaan pertama menggunakan *k*-NN dengan metrik jarak Euclidean dan *predictor* *x,y*. Pemilihan metrik jarak Euclidean didasarkan pada hasil penelitian sebelumnya berdasarkan karakteristik data. Percobaan kedua menggunakan pengklasifikasi SVM dengan fungsi *kernel cubic* dan *predictor* yang digunakan adalah *x,y*. Percobaan ketiga tetap menggunakan SVM dengan fungsi *kernel cubic* tetapi ada perubahan pada *predictor*, yaitu *roll* dan *pitch*. Setelah tiga percobaan dilakukan, selanjutnya dipilih model terbaik hasil pelatihan data untuk digunakan menguji data baru. Seperti terlihat pada Gbr. 2, terdapat lima buah gerakan simulasi interaksi objek virtual tiga dimensi. Tangan yang digunakan adalah tangan sebelah kanan dan dipasang sensor Myo Armband. Pada gerakan pertama yaitu mengangkat (ANK), terdapat tiga kegiatan. Pertama adalah lengan bergerak turun menuju ke objek tujuan. Kemudian, diikuti dengan proses menggenggam benda virtual, diikuti gerakan mengangkat benda. Gerakan kedua yaitu memungut (PU). Kegiatan yang dilakukan adalah menggerakkan lengan ke bawah untuk memungut benda virtual. Selanjutnya menggunakan jempol dan telunjuk menjepit benda, diikuti gerakan mengangkat. Gerakan yang ketiga adalah gerakan memegang (PDK) benda virtual. Kegiatan yang dilakukan adalah menggerakkan lengan ke arah benda yang sejajar dengan tangan. Selanjutnya adalah menggenggam benda virtual tersebut. Gerakan yang keempat adalah menyapu ke kanan (SDKN). Kegiatan yang dilakukan adalah menggerakkan pergelangan tangan seolah mendorong benda virtual menggunakan punggung telapak tangan. Sebaliknya, gerakan menyapu ke kiri (SDKI) adalah menggerakkan pergelangan tangan untuk mendorong benda menggunakan telapak tangan ke arah kiri. Setiap gerakan dilakukan lima kali berturut-turut untuk memperoleh beberapa rangkaian koordinat. Setelah pengambilan koordinat dilakukan menggunakan gerakan tangan yang terdefinisi pada Gbr. 3, langkah selanjutnya adalah melihat sebaran data menggunakan *Gaussian mixture model*. Hal ini harus dilakukan untuk dapat menentukan pengklasifikasi terbaik yang akan digunakan melalui seleksi fitur.

A. Seleksi Fitur

Tahapan seleksi fitur dibutuhkan untuk membantu mempercepat proses pengklasifikasian. Hal ini perlu dilakukan mengingat data mentah hasil perekaman oleh perangkat sensor masih memiliki beberapa fitur yang tidak terpakai. Rentang data antara berbagai fitur hasil perekaman data juga berpengaruh dalam proses pengklasifikasian. Rentang data yang sangat lebar akan mengakibatkan proses pengenalan dan pembentukan model gagal dilakukan, dengan kata lain akurasi pendeteksian menjadi sangat rendah. Berbagai algoritme dapat dipakai untuk melakukan seleksi

fitur. Salah satu yang andal digunakan adalah *Gaussian mixture model*. Penjelasan pemanfaatannya diuraikan sebagai berikut.



Gbr. 3 Lima buah gerakan simulasi interaksi objek virtual 3D.

Hasil rekaman menggunakan sensor Myo Armband menghasilkan beberapa kelompok data. Kelompok pertama adalah akselerometer, berisi tiga fitur yang mengukur percepatan sensor terhadap aksi yang dilakukan oleh tangan dan hasilnya terekam dalam x, y, z . Kelompok kedua adalah *electromyograph*, berisi delapan fitur hasil perekaman denyut listrik pada otot lengan. Kelompok ketiga adalah *gyro*, berisi tiga buah fitur hasil pengukuran posisi sensor pada tangan selama gerakan. Fiturnya terekam dalam bentuk koordinat x, y, z . Kelompok keempat adalah *orientation*, berisi empat fitur yang merupakan hasil pengukuran orientasi tubuh. Kelompok terakhir adalah *orientation Euler*, berisi tiga fitur yang merupakan hasil pengukuran orientasi tubuh terhadap sistem koordinat dan disimpan dalam *roll*, *pitch*, dan *yaw*. Kombinasi data tersebut diperiksa menggunakan *Gaussian mixture model*, dengan persiapan data untuk pembentukan modelnya adalah sebagai berikut. Rentang data terkecil sampai terbesar dijadikan data pada sumbu y dalam fungsi distribusi normal. Masing masing fitur diambil rata-rata dan simpangan bakunya. Seluruh fitur yang telah berbentuk rata-rata dan simpangan baku dimasukkan sebagai nilai sumbu x pada fungsi distribusi normal. Fungsi yang digunakan adalah *cumulative distribution function* dan *probability density function* dengan urutan persamaan sebagai berikut.

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} (x_1 + x_2 + \dots + x_n) \quad (1)$$

dengan $\{x_1, x_2, \dots, x_n\}$ adalah nilai pengamatan dari sampel dan X adalah rata-rata pengamatan. Selanjutnya, persamaan standar deviasi yang digunakan adalah

$$S_N = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}. \quad (2)$$

Selanjutnya digunakan variabel μ sebagai rata-rata dari distribusi σ , standar deviasi σ^2 sebagai varian, sehingga *probability density function* didefinisikan sebagai berikut.

$$f(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}. \quad (3)$$

Dengan distribusi normal f dengan rata-rata μ dan deviasi σ , maka *cummulative distribution function* didefinisikan sebagai berikut.

$$F(x) = \Phi\left(\frac{x-\mu}{\sigma}\right) = \frac{1}{2} \left[1 + \operatorname{erf}\left(\frac{x-\mu}{\sigma\sqrt{2}}\right) \right]. \quad (4)$$

Setelah melalui tahap seleksi fitur menggunakan *Gaussian mixture model*, langkah selanjutnya adalah melakukan klasifikasi terbimbing terhadap seluruh data. Disiapkan tiga buah percobaan, yaitu menggunakan k -NN dengan metrik jarak Euclidean, SVM dengan kernel *cubic* dan *predictor x, y* serta *predictor roll, pitch*.

B. Pengklasifikasian

Percobaan pertama menggunakan k -NN dengan metrik jarak Euclidean. Dalam metrik ini jumlah tetangga akan dibandingkan secara terus menerus adalah satu. Persamaan jarak Euclidean didefinisikan dengan lambang d adalah jarak, p dan q adalah nilai yang diukur, i adalah indeks, dan n adalah dimensi data. Metrik jarak Euclidean didefinisikan sebagai berikut.

$$d(p, q) = d(q, p) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2}. \quad (5)$$

Hal ini dimungkinkan dengan membentuk satu himpunan bobot W , masing-masing satu untuk setiap data yang berdekatan, ditentukan oleh jarak relatif dari setiap data yang berdekatan dengan titik referensi p . Penentuan jarak menggunakan dua titik dilambangkan dengan x dan x_i . Kedua titik masuk ke dalam himpunan p_i , dilambangkan sebagai $D(x, p)$. Proses dalam algoritme k -NN dilakukan dengan mengukur bobot masing-masing k tetangga dengan jarak antara titik-titik x_n , bergeser ke r_i tetangga terdekat. Algoritme persamaannya ditulis sebagai berikut.

$$I(x_p) = \frac{\operatorname{argmax}}{veV} \sum_{j=i}^n r_j \beta(y, i(y_j)) \quad (6)$$

dengan bobotnya adalah

$$r_j = \frac{1}{d(x_p, x_j)^2}. \quad (7)$$

Selanjutnya, semua data yang telah dilatih digunakan untuk perhitungan pembobotan melalui (8).

$$F(x_q) = \frac{\sum_{i=1}^k w_j f(x_i)}{\sum_{i=1}^k w_i}. \quad (8)$$

Proses pengklasifikasian yang kedua menggunakan SVM. Cara kerjanya adalah sebagai berikut. Sebaran data pada bidang dua dimensi ditransformasikan menggunakan fungsi *kernel* polinomial ke bentuk tiga dimensi. Selanjutnya daerah

tiga dimensi yang terbentuk, berisi kelompok data, dapat dipisahkan menggunakan fungsi linier. Persamaan fungsi *kernel cubic* didefinisikan sebagai berikut.

$$k(x_1, x_2) = (x_1^T x_2 + 1)^3. \quad (6)$$

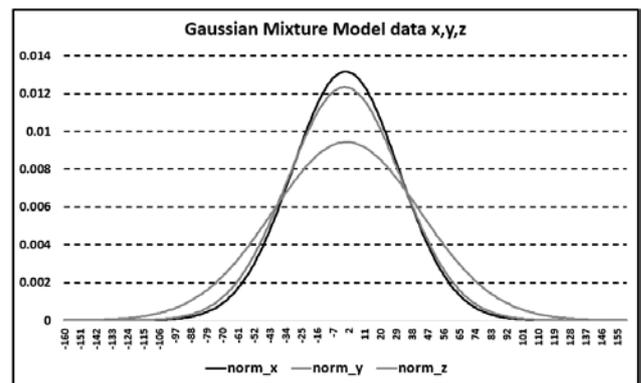
C. Pengujian

Pada tahap ini telah diperoleh model terlatih untuk memeriksa gestur menggunakan data baru. Meskipun dalam proses pelatihan data telah menggunakan validasi *10-fold cross validation*, pengujian menggunakan data baru dibutuhkan untuk melihat unjuk kerja model. Hasil pengujian ditampilkan dalam bentuk grafik batang yang menggambarkan akurasi masing-masing pengklasifikasi. Sebanyak lima gerakan yang sama diulang perekaman datanya. Kemudian tanpa menggunakan label, tiap data gerakan diprediksi menggunakan model terlatih. Keseluruhan aliran proses pengenalan gestur sampai dengan proses pengujian menggunakan data baru diperlihatkan pada Gbr. 2, model proses yang diusulkan.

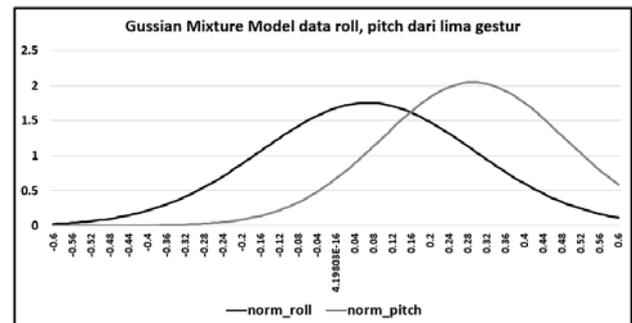
IV. HASIL DAN PEMBAHASAN

Berdasarkan tahap pelaksanaan penelitian yang telah diuraikan sebelumnya, hasil pertama diperoleh dari beberapa grafik *Gaussian mixture model*. Sebanyak enam buah fitur diperiksa untuk melihat sebarannya. Pada tiga fitur pertama, yaitu data *gyroscope x,y,z*, diperoleh rentang yang cukup untuk pengklasifikasi melakukan pemodelan. Rentang nilai tersebut ditunjukkan pada Gbr. 4, dengan sebaran *x* di antara 0,008 sampai 0,01 sedangkan sebaran *y* dan *z* pada rentang 0,012 sampai 0,013. Grafik ini dipisahkan dari grafik *roll*, *pitch*, dan *yaw* untuk memudahkan pengamatan. Hal ini diakibatkan oleh perbedaan ukuran antara data sensor *gyroscope* dan data sensor *orientation Euler* yang ada pada Myo Armband. Sensor ini memberikan tiga buah fitur, yaitu *roll*, *pitch*, dan *yaw*. Terlihat pada Gbr. 5, sebaran data *roll* berada pada puncaknya di angka 1,75 sedangkan sebaran data *pitch* berada pada puncaknya di angka 2,05. Terbentuk rentang yang cukup jauh antara kedua fitur, yaitu 0,05 sampai 0,3. Hal ini memudahkan pengklasifikasi melakukan tugas pemodelan dan menghasilkan model terlatih dengan akurasi yang tinggi. Hasil dari *Gaussian mixture model* ini dapat digunakan untuk melakukan pemilihan *predictor* pada proses klasifikasi. Berdasarkan rentang yang lebar antara *roll* dan *pitch*, *predictor* untuk pengklasifikasi SVM digunakan. Grafik *Gaussian mixture model* yang terakhir, yaitu data *yaw*, dipisahkan dari *roll* dan *pitch* karena perbedaan nilai yang terlalu besar. Perbedaan ini membuat grafik tidak terlihat jika ketiga fitur digabung ke dalam satu grafik.

Gbr. 6 menunjukkan, tidak terbentuk kurva normal seperti lazimnya grafik *Gaussian mixture model*. Tipisnya rentang data dari angka +0,6 sampai 0,6 membuat data *yaw* menjadi fitur yang sebenarnya dapat diabaikan. Namun, dalam makalah ini pengabaian tidak dilakukan, sebab meskipun memberikan rentang angka yang sangat tipis, *roll*, *pitch*, dan *yaw* adalah kesatuan. Pemisahan grafik *yaw* dilakukan hanya untuk memperjelas fitur yang sebaiknya digunakan sebagai *predictor*.



Gbr. 4 *Gaussian mixture model* untuk data *gyroscope x,y,z*.



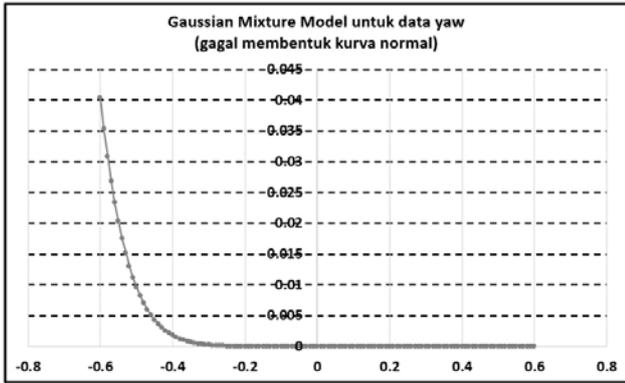
Gbr. 5 *Gaussian mixture model* untuk data *roll* dan *pitch*.

Pemilihan penggunaan data *x,y,z*, *raw*, *pitch*, dan *yaw* sebaliknya menunjukkan sebaran pada *Gaussian mixture model* yang sangat baik, 99,86%, untuk klasifikasi. Pemilihan *predictor* menentukan tingkat akurasi dalam proses klasifikasi. Hal ini dapat dilihat pada Gbr. 5, melalui sebaran data kurva normal dengan nilai 1,7 sampai 2,1 pada sumbu *y* skala grafik *Gaussian mixture model*. Hasil selanjutnya diperoleh dari proses pelatihan model menggunakan pengklasifikasi *k-NN* dengan dengan metrik jarak Euclidean. Percobaan pertama diperlihatkan pada Tabel I. Sebanyak 3.492 observasi tersebar dalam lima gestur. Digunakan *10-fold cross validation*, 5 *predictor*, satu label tanggapan, dan 5 kelas tanggapan. Percobaan ini menghasilkan *confusion matrix* dengan akurasi prediksi gestur di atas 99%. Terdapat lima buah gestur yang berhasil diprediksi. Akurasi prediksi terbagi dalam dua kelompok, yaitu menghasilkan akurasi sebesar 100% dan kedua 99,43%.

Seperti terlihat pada Tabel I, kelompok pertama terdiri atas gestur ANK, PU, dan SDKI. Sedangkan kelompok kedua adalah PDK dan SDKN. Gestur PDK, dengan total observasi sebanyak 698, berhasil diprediksi secara tepat sebanyak 694. Namun, terdapat dua observasi yang diprediksi sebagai SDKI dan dua lagi sebagai SDKN. Pada gestur SDKN, dengan total observasi sebanyak 699, terdapat empat gestur yang salah diprediksi oleh pengklasifikasi. Keempat gestur tersebut terdeteksi sebagai SDKI.

Pada percobaan yang kedua, dengan observasi yang sama sebesar 3.492, dihasilkan akurasi dengan persentase masih di atas 99%. Jika dibandingkan dengan hasil pada *confusion matrix* pertama di Tabel I, terdapat perbedaan yang signifikan dalam pengelompokan hasil. Pada Tabel II terlihat sebanyak

empat buah gestur tidak berhasil diprediksi 100%. Angka prediksi terkecil diperoleh sebesar 99,57% untuk SDKN. Sebanyak tiga buah gestur, yaitu PDK, PU, dan SDKI memperoleh akurasi sebesar 99,86%. Tiga gestur tersebut masing-masing memiliki 698 observasi. Untuk gestur PDK hanya satu observasi yang salah diprediksi menjadi SDKN. Satu observasi dari PU terprediksi sebagai PDK dan satu dari SDKI juga sebagai PDK.



Gbr. 6 Gaussian mixture model untuk data yaw.

TABEL I
CONFUSION MATRIX K-NN BER-PREDICTOR X,Y

		Kelas yang Diprediksi					ACC
		ANK	PDK	PU	SDKI	SDKN	
Kelas Asli	ANK	699					100,00%
	PDK		694		2	2	99,43%
	PU			698			100,00%
	SDKI				698		100,00%
	SDKN				4	695	99,43%

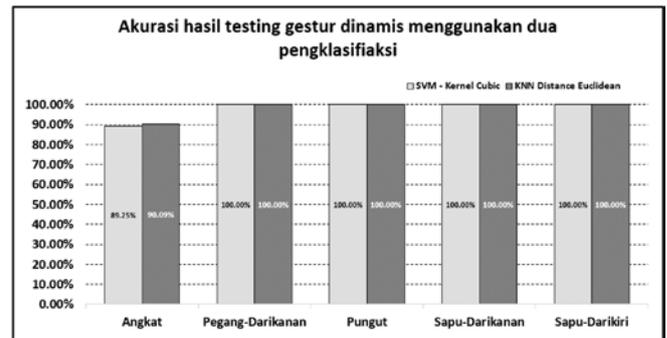
TABEL II
CONFUSION MATRIX SVM BER-PREDICTOR X,Y

		Kelas yang Diprediksi					ACC
		ANK	PDK	PU	SDKI	SDKN	
Kelas Asli	ANK	699					100,00%
	PDK		697			1	99,86%
	PU		1	697			99,86%
	SDKI		1		697		99,86%
	SDKN				3	696	95,57%

Pada percobaan yang ketiga, dilakukan perubahan *predictor* dari *x,y* menjadi *roll, pitch*. Perubahan ini menghasilkan peningkatan akurasi. Jika dibandingkan dengan percobaan pertama dan kedua, gestur PDK hanya berkisar pada angka 99,43% dan 99,86%, sedangkan pada percobaan ketiga terjadi kenaikan sampai dengan 100%, seperti terlihat pada Tabel III. Berdasarkan ketiga percobaan yang telah dilakukan, dipilih model dengan akurasi terbaik untuk menguji data gestur yang baru. Penentuan *predictor raw* dan *pitch* dalam proses klasifikasi mampu meningkatkan akurasi pembentukan model sebesar 1,1%.

TABEL III
CONFUSION MATRIX SVM BER-PREDICTOR ROLL, PITCH

		Kelas yang Diprediksi					ACC
		ANK	PDK	PU	SDKI	SDKN	
Kelas Asli	ANK	699					100,00%
	PDK		698				100,00%
	PU		1	697			99,86%
	SDKI				698		100,00%
	SDKN				3	695	95,57%



Gbr. 7 Persentase hasil pengujian gestur pada data baru.

Peningkatan tersebut semula 98,8% menjadi 99,9%. Empat gerakan berhasil dimodelkan dengan akurasi di atas 99,9%, dan empat gerakan yang sama dapat diprediksi oleh model dengan akurasi juga di atas 99,9%. Satu gerakan, yaitu angkat, hanya dapat diprediksi oleh model dengan akurasi 89,9%. Hasil pengujian menggunakan data yang baru juga menunjukkan hasil yang baik. Hal ini terlihat dari diperolehnya angka akurasi sebesar 100% untuk keempat gestur.

Selanjutnya, Gbr. 7 memperlihatkan hasil penggunaan model yang telah dilatih pada data yang baru. Terlihat dua buah pengklasifikasi dengan hasil terbaik, yaitu *k-NN* dan SVM, mampu mendapatkan akurasi 100% untuk empat buah gestur, yaitu: pegang dari kanan, pungut, sapu dari kanan, dan sapu dari kiri. Sebuah gestur, yaitu angkat, tidak berhasil dikenali dengan tingkat akurasi seperti keempat gestur lainnya. Perolehannya hanya mencapai 89% akurasi pengenalan oleh SVM dan 90% akurasi pengenalan oleh *k-NN*.

V. KESIMPULAN

Dari hasil penelitian yang telah dilakukan dapat disimpulkan beberapa hal sebagai berikut. Data *orientation* dan *orientation Euler* menghasilkan akurasi yang tinggi dalam pendeteksian gestur lengan dinamis. Keakurasian ini harus didukung oleh pemilihan *predictor* yang tepat. *Gaussian mixture model* dapat membantu peneliti menentukan fitur yang baik untuk dijadikan *predictor*.

Penelitian ini menghasilkan model gerakan lengan dinamis yang dapat memprediksi lima gerakan secara terukur. Selanjutnya, pengembangan aplikasi yang menggunakan gestur lengan dinamis pada ruang virtual dapat dilakukan untuk menjawab keterbatasan akses terhadap benda koleksi

peninggalan warisan budaya. Secara keseluruhan, dapat disimpulkan bahwa lima buah gestur yang terukur untuk interaksi dalam lingkungan virtual dapat digunakan.

UCAPAN TERIMA KASIH

Penelitian ini didukung oleh Beasiswa Pascasarjana Kementerian Riset Teknologi & Pendidikan Tinggi. Terima kasih yang sebesar-besarnya disampaikan kepada seluruh mahasiswa di laboratorium komputer B401 Insitut Teknologi Sepuluh Nopember yang telah secara sukarela ikut berpartisipasi dalam proses pengambilan data dan uji coba. Tidak lupa disampaikan juga terima kasih kepada kepala Laboratorim Komputer B417 Osaka City University, Osaka, Japan, Prof. Hideya Takahashi dan Prof. Kayo Yoshimoto, atas semua dukungan dan pemberian fasilitas yang telah digunakan selama melakukan penelitian.

REFERENSI

- [1] S. Sumpeno, A. Zaini, M. Muhtadin, S.M.S. Nugroho, E.M. Yuniarno, dan I.K.E. Purnama, "Ragam Teknologi Informasi untuk Revitalisasi Museum," *Seminar Nasional Otomasi Industri dan Teknologi Informasi*, 2015, Vol. 1, hal. 1-6.
- [2] S. Sumpeno dan A.G. Sooi, "3D Stereoskopik untuk Peninggalan Sejarah," *AEK FDI*, Vol. 1, No. 1, hal. 33-37, Dec. 2016.
- [3] A.G. Sooi, S. Sumpeno, dan M.H. Purnomo, "User Perception on 3D Stereoscopic Cultural Heritage Ancient Collection," *Proceedings of the The 2nd International Conference in HCI and UX on Indonesia 2016*, 2016, hal. 112-119.
- [4] A.G. Sooi, A. Nugroho, M.N.A. Azam, S. Sumpeno, dan M.H. Purnomo, "Virtual artifact: Enhancing Museum Exhibit Using 3D Virtual Reality," *2017 TRON Symposium (TRONSHOW)*, 2017, hal. 1-5.
- [5] S.L. Kim, H.J. Suk, J.H. Kang, J.M. Jung, T.H. Laine, dan J. Westlin, "Using Unity 3D to Facilitate Mobile Augmented Reality Game Development," *2014 IEEE World Forum on Internet of Things (WF-IoT)*, 2014, hal. 21-26.
- [6] Z. Tůma, J. Tůma, R. Knoflíček, P. Blecha, dan F. Bradáč, "The Process Simulation Using by Virtual Reality," *Procedia Eng.*, 2014, Vol. 69, hal. 1015-1020.
- [7] G. Kontogianni dan A. Georgopoulos, "A Realistic Gamification Attempt for the Ancient Agora of Athens," *2015 Digital Heritage*, 2015, Vol. 1, hal. 377-380.
- [8] L. Chittaro dan F. Buttussi, "Assessing Knowledge Retention of an Immersive Serious Game vs. a Traditional Education Method in Aviation Safety," *IEEE Trans. Vis. Comput. Graph.*, Vol. 21, No. 4, hal. 529-538, Apr. 2015.
- [9] E. Redondo, D. Fonseca, A. Sánchez, dan I. Navarro, "New Strategies Using Handheld Augmented Reality and Mobile Learning-teaching Methodologies, in Architecture and Building Engineering Degrees," *Procedia Comput. Sci.*, Vol. 25, hal. 52-61, Jan. 2013.
- [10] I.G.A. Dharmayasa, S. Sumpeno, I.K.E. Purnama, dan A.G. Sooi, "Exploration of Prayer Tools in 3D Virtual Museum Using Leap Motion for Hand Motion Sensor," *2017 TRON Symposium (TRONSHOW)*, 2017, hal. 1-8.
- [11] A.G. Sooi, K. Yoshimoto, H. Takahashi, S. Sumpeno, dan M.H. Purnomo, "Dynamic Hand Gesture Recognition on 3D Virtual Cultural Heritage Ancient Collection Objects Using k-Nearest Neighbor," *Eng. Lett.*, Vol. 26, No. 3, hal. 356-363, 2018.
- [12] F. Bruno, S. Bruno, G. De Sensi, M.L. Luchi, S. Mancuso, dan M. Muzzupappa, "From 3D Reconstruction to Virtual Reality: A Complete Methodology for Digital Archaeological Exhibition," *J. Cult. Herit.*, Vol. 11, No. 1, hal. 42-49, 2010.
- [13] M. Nabil dan F. Saleh, "3D Reconstruction from Images for Museum Artefacts: A Comparative Study," *2014 International Conference on Virtual Systems Multimedia (VSMM)*, 2014, hal. 257-260.
- [14] D. Rojas, B. Kapralos, A. Hogue, K. Collins, L. Nacke, S. Cristancho, C. Conati, dan A. Dubrowski, "The Effect of Sound on Visual Fidelity Perception in Stereoscopic 3-D," *IEEE Trans. Cybern.*, Vol. 43, No. 6, hal. 1572-1583, Dec. 2013.
- [15] M. Hayashi, S. Bachelder, M. Nakajima, dan A. Iguchi, "A New Virtual Museum Equipped with Automatic Video Content Generator," *2014 International Conference on Cyberworlds (CW)*, 2014, hal. 377-383.
- [16] F. Gabellone, I. Ferrari, M.T. Giannotta, dan A. Dell'Aglio, "From Museum to Original Site: A 3D Environment for Virtual Visits to Finds Re-Contextualized in Their Original Setting," *Digital Heritage International Congress (DigitalHeritage) 2013*, 2013, Vol. 2, hal. 215-222.
- [17] A.-H.G. Abulrub, K. Budabuss, P. Mayer, dan M.A. Williams, "The 3D Immersive Virtual Reality Technology Use for Spatial Planning and Public Acceptance," *Procedia - Soc. Behav. Sci.*, Vol. 75, hal. 328-337, Apr. 2013.
- [18] F. Caputo, A. Greco, E. D'Amato, I. Notaro, dan S. Spada, "On the Use of Virtual Reality for a Human-Centered Workplace Design," *Procedia Struct. Integr.*, Vol. 8, hal. 297-308, Jan. 2018.
- [19] H. Zhuang, M. Yang, Z. Cui, dan Q. Zheng, "A Method for Static Hand Gesture Recognition Based on Non-Negative Matrix Factorization and Compressive Sensing," *IAENG Int. J. Comput. Sci.*, Vol. 44, No. 1, hal. 52-59, Feb. 2017.
- [20] K. Barczewska dan A. Drozd, "Comparison of Methods for Hand Gesture Recognition Based on Dynamic Time Warping Algorithm," *2013 Federated Conference on Computer Science and Information Systems*, 2013, hal. 207-210.
- [21] W. Lu, Z. Tong, dan J. Chu, "Dynamic Hand Gesture Recognition with Leap Motion Controller," *IEEE Signal Process. Lett.*, Vol. 23, No. 9, hal. 1188-1192, Sep. 2016.
- [22] R. Srivastava dan P. Sinha, "Hand Movements and Gestures Characterization Using Quaternion Dynamic Time Warping Technique," *IEEE Sens. J.*, Vol. 16, No. 5, hal. 1333-1341, Mar. 2016.
- [23] Khamid, A. D. Wibawa, dan S. Sumpeno, "Gesture Recognition for Indonesian Sign Language Systems (ISLS) Using Multimodal Sensor Leap Motion and Myo Armband Controllers Based-on Na #xeff;ve Bayes Classifier," *2017 International Conference on Soft Computing, Intelligent System and Information Technology (ICSIIIT)*, 2017, hal. 1-6.
- [24] D. Wu, L. Pigou, P.-J. Kindermans, N.D.-H. Le, L. Shao, J. Dambre, dan J.-M. Odobez, "Deep Dynamic Neural Networks for Multimodal Gesture Segmentation and Recognition," *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol. 38, No. 8, hal. 1583-1597, Agt. 2016.
- [25] P. Lorrentz, "Classification of Incomplete Data by Observation," *Engineering Letters*, Vol. 18, No. 4, hal. 1-10, 2010.
- [26] A.N. Rumaksari, S. Sumpeno, dan A.D. Wibawa, "Background Subtraction Using Spatial Mixture of Gaussian Model with Dynamic Shadow Filtering," *2017 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, 2017, hal. 296-301.
- [27] M.S. Annas, A. Rizal, dan R.D. Atmaja, "Pengenalan Individu Berdasarkan Gait Menggunakan Sensor Girooskop," *J. Nas. Tek. Elektro Dan Teknol. Inf. JNTETI*, Vol. 6, No. 2, hal. 210-214, 2017.
- [28] D. Huynh, D. Tran, and W. Ma, "Contextual Analysis for the Representation of Words," *IAENG Int. J. Comput. Sci.*, Vol. 41, No. 2, hal. 1-5, 2014.
- [29] P. Zhang, X. Zhang, dan W. Wang, "The General Lp-Dual Mixed Brightness Integrals," *IAENG Int. J. Appl. Math.*, Vol. 47, No. 2, hal. 1-5, 2016.
- [30] A. Handayani, A. Jamal, dan A.A. Septiandri, "Evaluasi Tiga Jenis Algoritme Berbasis Pembelajaran Mesin untuk Klasifikasi Jenis Tumor P payudara," *J. Nas. Tek. Elektro Dan Teknol. Inf. JNTETI*, Vol. 6, No. 4, hal. 394-403, 2017.