

BAB II

KAJIAN PUSTAKA

2.1. Penelitian Relevan

Penelitian yang sama mengenai verifikasi tanda tangan telah dilakukan sebelumnya oleh beberapa peneliti dalam menggunakan metode yang sama maupun metode yang berbeda. Penelitian yang dilakukan sebelumnya diantaranya yaitu:

2.1.1. Verifikasi Citra Tanda Tangan Menggunakan Metode *Prewitt* dan *Learning Vector Quantization*

Dalam penelitian yang dilakukan oleh (Sefta & Hidayatulloh, 2018) dengan judul “Verifikasi Citra Tanda Tangan Menggunakan Metode *Prewitt* dan *Learning Vector Quantization*”. Dalam penelitian tersebut terdapat sebuah permasalahan yaitu seringnya terjadi kasus pemalsuan tanda tangan yang disebabkan oleh sistem verifikasi tanda tangan yang masih dilakukan dengan cara membandingkan tanda tangan secara langsung dengan indera penglihatan yang memiliki banyak kelemahan jika melakukan proses verifikasi tanda tangan secara terus menerus. Penelitian ini menggunakan tanda tangan di atas kertas yang discan. Metode yang digunakan pada penelitian tersebut adalah *Prewitt* dan *Learning Vector Quantization*. Metode *Prewitt* digunakan untuk deteksi tepi, yang mencirikan batas-batas objek yang berguna untuk segmentasi dan identifikasi objek di dalam citra. Sedangkan metode *Learning Vector Quantization* digunakan pada tahap ekstraksi ciri, dimana pada tahap ini dilakukan pencocokan dengan membandingkan bobot yang ada pada data latih.

Hasil penelitian dari verifikasi citra tanda tangan menggunakan metode *Prewitt* dan *Learning Vector Quantization* dengan penghitung vektor dapat mengekstraksi fitur tanda tangan untuk memproses vektor yang digunakan dalam penghitungan vektor untuk mengenali tanda tangan asli dan tanda tangan palsu. Penelitian ini dapat mempermudah pendeteksian keaslian tanda tangan.

2.1.2. Penerapan Ciri *Geometric* Pada Deteksi dan Verifikasi Tanda Tangan *Offline*

Dalam penelitian yang dilakukan oleh (Putri et al., 2018) dengan judul “Penerapan Ciri *Geometric* Pada Deteksi dan Verifikasi Tanda Tangan *Offline*”. Dalam penelitian tersebut terdapat sebuah permasalahan yaitu tidak adanya sistem verifikasi tanda tangan yang memiliki peningkatan akurasi cukup tinggi. Pada penelitian ini data yang digunakan berupa tanda tangan offline. Metode yang digunakan pada penelitian tersebut adalah metode *modified-K Nearest Neighbor (m-KNN)*, metode ini digunakan pada tahapan klasifikasi.

Hasil penelitian penerapan ciri *Geometric* pada deteksi dan verifikasi tanda tangan *offline* Kemampuan sistem untuk mengenali tanda tangan asli rendah, hal ini disebabkan oleh nilai FRR minimum yang dihasilkan sistem sebesar 46.5% sedangkan nilai FAR minimum sebesar 3%. Dengan begitu dalam melakukan pengenalan sistem pada tanda tangan palsu sudah baik. Dengan hasil tersebut didapatkan nilai akurasi sebesar 69,5%.

2.1.3. Peranan Kontur dan *Slope* dalam Pengenalan Keaslian Tanda Tangan Menggunakan *Dynamic Time Warping* dan *Polar Fourier Transform*

Dalam penelitian yang dilakukan oleh (Karisma et al., 2016) dengan judul “Peranan Kontur dan *Slope* dalam Pengenalan Keaslian Tanda Tangan Menggunakan *Dynamic Time Warping* dan *Polar Fourier Transform*”. Dalam penelitian tersebut terdapat sebuah permasalahan yaitu jumlah sampel tanda tangan sebagai data pembandingan saat proses verifikasi terbatas dan rendahnya sistem untuk mengenali tanda tangan seseorang dari beberapa model pemalsuan tanda tangan. Pada penelitian ini data yang digunakan berupa tanda tangan *offline*, dengan jumlah responden 31 orang, dan setiap orang membuat 15 tanda tangan sebagai sampel tanda tangan asli, dan sampel tanda tangan palsu diambil dari 31 orang responden yang berbeda, untuk mendapatkan 15 tanda tangan palsu dari setiap responden. Responden diminta untuk mempelajari tanda tangan dari korban sehingga nantinya akan didapatkan 15 tanda tangan asli dan 15 tanda tangan palsu. Secara keseluruhan data yang digunakan sebanyak 930 data tanda tangan dari 31 *dataset* yang masing-masing terdiri dari 30 tanda tangan. Metode

yang digunakan pada penelitian tersebut adalah metode *Dynamic Time Warping* dan *Fourier Transform*, metode *Dynamic Time Warping* digunakan untuk mendapatkan kontur dari citra, sedangkan metode *Fourier Transform* digunakan untuk menghitung titik pusat citra polar.

Hasil penelitian Penerapan Ciri *Geometric* Pada Deteksi dan Verifikasi Tanda Tangan *Offline* adalah didapatkan bahwa hasil kombinasi dua metode ekstraksi fitur DTW dan PFT secara keseluruhan rata-rata *dataset* yang ada memiliki akurasi sebesar 93,23%. Dari hasil penelitian didapatkan bahwa kombinasi DTW dan PFT lebih baik dibandingkan metode DTW dan PFT yang berdiri sendiri untuk mengenali keaslian tanda tangan dalam penelitian ini. (Karisma et al., 2016).

2.1.4. *Deep Learning* Verifikasi Kemiripan Wajah Dengan Arsitektur Jaringan *Siamese*

Dalam penelitian yang dilakukan oleh (Imam, 2019) dengan judul “*Deep Learning* Verifikasi Kemiripan Wajah Dengan Arsitektur Jaringan *Siamese*”. Dalam penelitian tersebut terdapat sebuah permasalahan yaitu belum ada sistem verifikasi kemiripan pada wajah manusia. Pada penelitian ini data yang digunakan berupa *dataset* VGG (Visual Geometry Group) Face v2 sebagai *Dataset* untuk data latih dan *Dataset* Labeled Face in the Wild (LFW) sebagai data uji coba. *Dataset* VGG Face v2 memiliki 9000 jenis identitas dengan variasi etnis, aksen, profesi dan umur yang berbeda dan memiliki 3,3 juta gambar, sedangkan *Dataset* LFW disediakan oleh University of Massachusetts, *dataset* ini merupakan acuan pengujian seluruh peneliti computer vision dalam bidang pengenalan wajah saat ini. (Imam, 2019). Metode yang digunakan pada penelitian tersebut adalah metode *deep learning* dengan arsitektur jaringan *Siamese Network*, metode ini digunakan untuk mempelajari fitur-fitur yang ada pada wajah secara otomatis dengan mempelajari pola pada sekumpulan data dalam jumlah besar tanpa memerlukan pengetahuan tambahan dari lingkup luar (prior knowledge), cukup hanya dengan analisa otomatis pada data yang diberikan (feature extraction). (Imam, 2019).

Hasil dari penelitian *deep learning* verifikasi kemiripan wajah dengan arsitektur jaringan *Siamese* adalah Arsitektur jaringan *Siamese* berhasil mempelajari fitur wajah pada *Dataset* VGGv2 menggunakan ResNet-50 sehingga

mampu menghasilkan embedding yang baik (Imam, 2019). Model berhasil mempelajari fitur pada data training dan telah diuji pada data testing dan mendapatkan nilai AUC sebanyak 97%. (Imam, 2019).

2.1.5. *Deepsign: Efficient Siamese Convolutional Neural Networks For Signature Verification*

Dalam penelitian yang dilakukan oleh (Wang & Ko, n.d.) dengan judul “*Deepsign: Efficient Siamese Convolutional Neural Networks For Signature Verification*”. Dalam penelitian tersebut terdapat sebuah permasalahan yaitu verifikasi tanda tangan dilakukan secara langsung dengan menggunakan indera penglihatan manusia dan dilakukan secara kontinu sehingga mengurangi hasil dari verifikasi tanda tangan dan memakan waktu yang cukup lama sehingga sistem verifikasi tanda tangan menjadi kurang baik. Pada penelitian ini data yang digunakan berupa tanda tangan asli dan tanda tangan palsu. Metode yang digunakan pada penelitian tersebut adalah metode *Siamese Neural Network*.

Hasil dari penelitian *Deepsign: Efficient Siamese Convolutional Neural Networks For Signature Verification* adalah pengenalan sistem pada tanda tangan palsu sudah baik, serta *DeepSign*, yang memiliki parameter dan ukuran penyimpanan 25x lebih sedikit, model verifikasi tanda tangan canggih pada set data CEDAR dan BHSig260 dalam hal akurasi, presisi, penarikan kembali, dan AUROC.

Tabel 2. 1. Hasil Penelitian Terdahulu

No	Judul Penelitian	Pengarang & Tahun	Deskripsi Penelitian	Hasil
1	Verifikasi Citra Tanda Tangan Menggunakan Metode <i>Prewitt</i> dan <i>Learning Vector Quantization</i>	Asfanji Sefta & Syarif Hidayatulloh (2018)	Metode <i>Prewitt</i> digunakan untuk deteksi tepi, yang mencirikan batas-batas objek yang berguna untuk segmentasi dan identifikasi objek di dalam citra. Sedangkan metode <i>Learning Vector Quantization</i>	Dapat mengekstraksi fitur tanda tangan untuk memproses vektor yang digunakan dalam penghitungan vektor untuk mengenali tanda tangan asli dan tanda

			digunakan pada tahap ekstraksi ciri	tangan palsu.
2	Penerapan Ciri <i>Geometric</i> Pada Deteksi dan Verifikasi Tanda Tangan <i>Offline</i>	Wenny Ramadha Putri, dkk (2018)	Metode yang digunakan pada penelitian tersebut adalah metode <i>modified-K Nearest Neighbor (m-KNN)</i> , metode ini digunakan pada tahapan klasifikasi.	Kemampuan sistem untuk mengenali tanda tangan asli rendah, didapatkan nilai akurasi sebesar 69,5%.
3	Peranan Kontur dan <i>Slope</i> dalam Pengenalan Keaslian Tanda Tangan Menggunakan <i>Dynamic Time Warping</i> dan <i>Polar Fourier Transform</i>	Ignatia Dhian Estu Karisma, dkk (2016)	Metode yang digunakan pada penelitian tersebut adalah metode <i>Dynamic Time Warping</i> dan <i>Fourier Transform</i> , metode <i>Dynamic Time Warping</i> digunakan untuk mendapatkan kontur dari citra, sedangkan metode <i>Fourier Transform</i> digunakan untuk menghitung titik pusat citra polar.	Didapatkan bahwa hasil kombinasi dua metode ekstraksi fitur DTW dan PFT secara keseluruhan rata-rata <i>dataset</i> yang ada memiliki akurasi sebesar 93,23%
4	<i>Deep Learning</i> Verifikasi Kemiripan Wajah Dengan Arsitektur Jaringan <i>Siamese</i>	Kartarina & Hairul Imam (2019)	Metode yang digunakan pada penelitian tersebut adalah metode <i>deep learning</i> dengan arsitektur jaringan <i>Siamese Network</i> , metode ini digunakan untuk mempelajari fitur-fitur yang ada pada wajah secara otomatis dengan mempelajari pola pada sekumpulan	Model berhasil mempelajari fitur pada data training dan telah diuji pada data testing dan mendapatkan nilai AUC sebanyak 97%

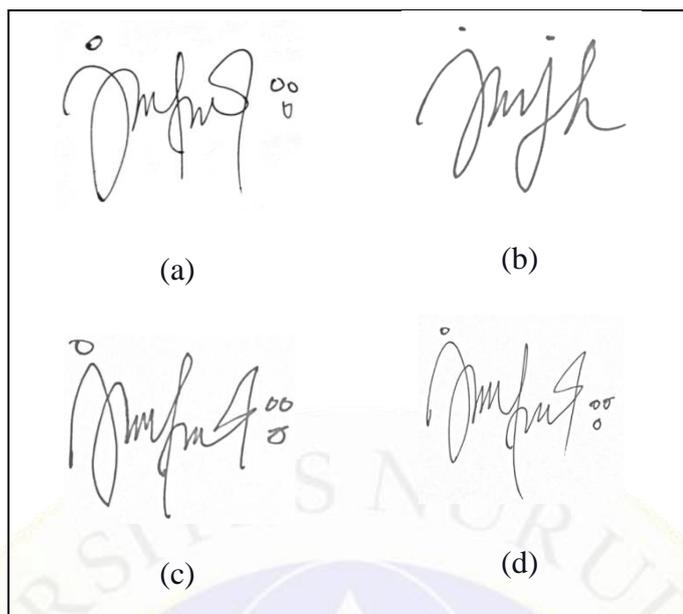
			data dalam jumlah besar tanpa memerlukan pengetahuan tambahan dari lingkup luar (prior knowledge)	
5	<i>DeepSign: Efficient Siamese Convolutional Neural Networks For Signature Verification</i>	Jonathan X Wang & Kevin Ko (2019)	Metode yang digunakan pada penelitian tersebut adalah metode <i>Siamese Neural Network</i>	pengenalan sistem pada tanda tangan palsu sudah baik, serta <i>DeepSign</i> , yang memiliki parameter dan ukuran penyimpanan 25x lebih sedikit

2.2. Landasan Teori

Dalam sebuah penelitian terdapat landasan teori yang menjadi dasar penalaran dari teori yang digunakan, adapun landasan teori pada penelitian ini sebagai berikut:

2.2.1. Model Pemalsuan Tanda Tangan

Validasi tanda tangan sangat sulit dilakukan jika data sampel yang ada sangat sedikit, contohnya seperti penarikan uang di teller bank, yang sistem validasi tanda tangan hanya dilakukan dengan 1 sampel data tanda tangan yang ada di buku tabungan nasabah bank, dengan beberapa model pemalsuan tanda tangan tentu ini sangat fatal jika terjadi kesalahan dalam sistem validasi tanda tangan yang ada. Berikut ini merupakan beberapa model pemalsuan tanda tangan:



Gambar 2. 1. Model pemalsuan tanda tangan, (a) tanda tangan asli; (b) tanda tangan palsu random; (c) tanda tangan palsu unskilled; (d) tanda tangan palsu skilled;

Seperti yang terlihat pada Gambar 2.1. bahwa terdapat beberapa model pemalsuan tanda tangan, ada pemalsuan secara random dimana pelaku pemalsuan tanda tangan hanya mengetahui nama dari korban tanpa pernah melihat tanda tangan asli dari korban. Kemudian terdapat model pemalsuan unskilled dimana pelaku hanya pernah melihat sekilas tanda tangan asli korban dan belum pernah melatih tanda tangan tersebut saat melakukan pemalsuan. Sedangkan untuk pemalsuan skilled maka pelaku sudah pernah melatih diri untuk memalsukan tanda tangan dari korban, sehingga didapatkan tanda tangan palsu yang hampir menyerupai tanda tangan asli korban (Karisma, Nugroho, & Adji, 2016).

2.2.2. Karakteristik Biometrika

Sistem pengenalan biometrika merupakan Sistem Otentifikasi (*Authentication System*) mengenali identitas seseorang secara otomatis menggunakan teknologi komputer, sistem akan mencocokkan identitas seseorang berdasarkan suatu ciri biometrika dengan suatu basis data acuan yang telah disiapkan sebelumnya. Sistem mampu memutuskan apakah hasil pengenalan sah atau tidak, diterima atau ditolak, dikenali atau tidak dikenali (Susanti & Wulanningrum, 2020).

Pada karakteristik biometrika dibedakan menjadi karakteristik fisik dan perilaku. Karakteristik fisik seperti pengenalan wajah, sidik jari, retina dan suara, sedangkan karakteristik perilaku pengenalan tanda tangan yang akan dibahas dalam penelitian ini. Dalam sistem biometrika memiliki kelebihan dan kekurangan, tetapi tergantung pada sistem apa yang akan dibuat dan penerapannya (Susanti & Wulanningrum, 2020).

2.2.3. Citra Warna

Citra warna atau citra RGB merupakan citra yang masing-masing pixel memiliki tiga komponen warna, yaitu merah(*red*), biru(*blue*), dan hijau(*green*). Warna yang di peroleh dari setiap pixel merupakan hasil yang ditentukan oleh kombinasi dari banyaknya penggunaan warna merah, biru, hijau yang disimpan pada bidang warna di lokasi pixel (Andono, T, & Muljono, 2017).

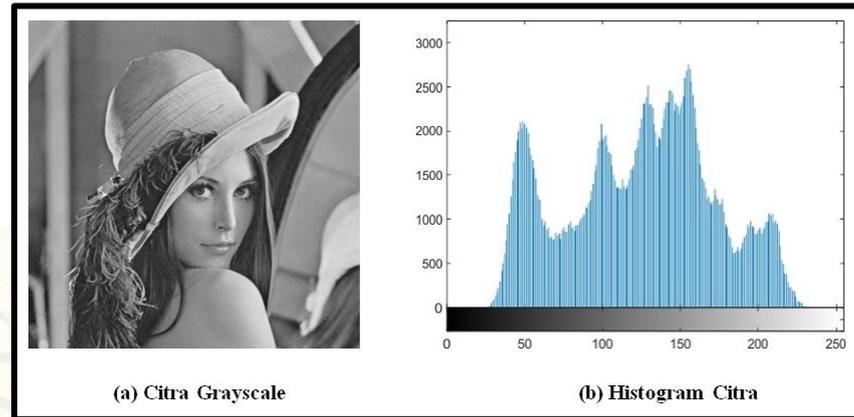
Seperti yang ditunjukkan pada Gambar 2.2, merupakan respirasi citra warna yang masing-masing warna kanal (terusan) atau warna penyusun ditunjukkan pada gambar. Gambar dengan warna sempurna ditunjukkan dengan nilai 255 dan hitam sempurna ditunjukkan dengan nilai 0. Pada gambar (a) menunjukkan gambar RGB dimana gambar tersebut merupakan citra warna yang ditangkap dengan menggunakan kamera. Gambar (b), (c), (d) merupakan hasil representasi kanal warna citra RGB.



Gambar 2. 2. Gambar citra warna (RGB) dan respirasi citra

2.2.4. Citra Grayscale

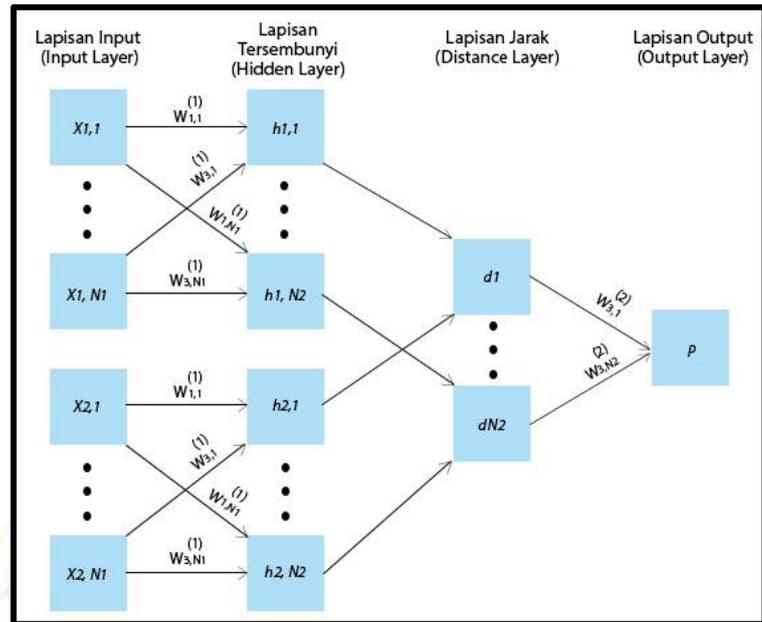
Citra *grayscale* adalah citra yang memiliki warna hitam, putih, dan keabuan. Citra *grayscale* merupakan matriks data yang memiliki nilai untuk mewakili banyaknya penggunaan warna setiap pixel dengan rentang 0 hingga 225 (Andono, T, & Muljono, 2017). Gambar 2.3 menunjukkan (a) gambar *graycale* dan juga (b) histogram dari gambar *grayscale*.



Gambar 2. 3. *Citra grayscale*

2.2.5. Siamese Network

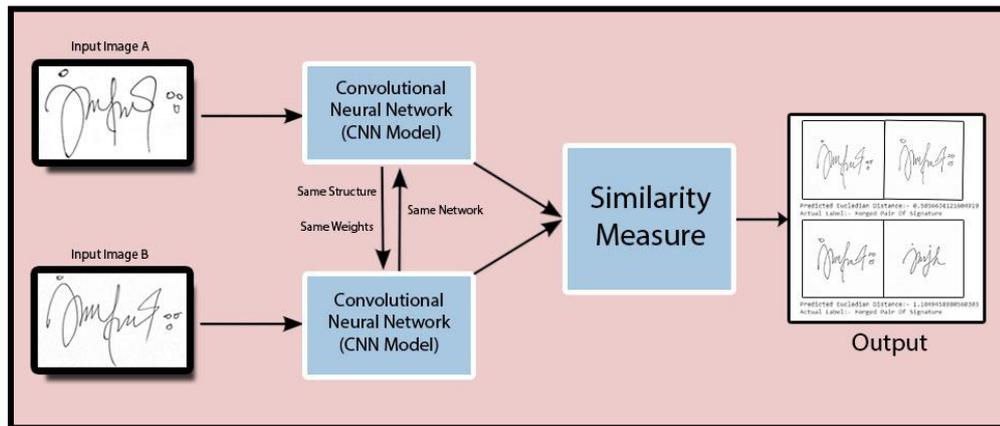
Siamese Network terdiri dari jaringan yang kembar dan menerima input berbeda tetapi digabungkan dengan fungsi energi di bagian atas. Fungsi ini menghitung beberapa metrik antara representasi fitur tingkat tertinggi di setiap sisi, dapat dilihat pada Gambar 2.4. Dua gambar yang sangat mirip tidak mungkin dipetakan oleh jaringannya masing-masing ke lokasi yang berbeda dalam ruang fitur karena setiap jaringan menghitung fungsi yang sama. Selain itu, *Siamese Network* setiap kali menyajikan dua gambar berbeda ke jaringan kembar, lapisan penyambung atas akan menghitung metrik yang sama seolah-olah akan menyajikan dua gambar yang sama tetapi menyajikan dua gambar ke kembar yang berlawanan (Bromley, Cun, Sackinger, & Shah, 1994).



Gambar 2. 4. *Siamese Network 2 layer* (Sumber : www.paperswithcode.com)

Dua lapisan tersembunyi (*Hidden Layer*) yang sederhana dari *Siamese Network* untuk klasifikasi biner dengan prediksi logistik (p). Struktur jaringan pekerjaan direplikasi di bagian atas dan bawah untuk membentuk jaringan kembar, dengan matriks bobot bersama di setiap lapisannya (Bromley, Cun, Sackinger, & Shah, 1994).

Siamese Network adalah kelas arsitektur jaringan saraf yang berisi dua atau lebih sub jaringan yang identik, artinya *Siamese Network* memiliki konfigurasi yang sama dengan parameter dan bobot yang sama. Pembaharuan parameter dicerminkan di kedua sub jaringan. Ini digunakan untuk mencari kesamaan input dengan membandingkan vektor fiturnya. Desain yang lebih jelas dari *Siamese Network* seperti yang digambarkan pada Gambar 2.5, adalah arsitektur jaringan saraf dimana dua jaringan saraf *konvolusional* dengan bobot yang sama bekerja secara *paralel*. Setiap jaringan mengambil input vektor yang berbeda, dalam hal ini data yang akan diproses dari dua input yang berbeda, kemudian akan menghasilkan output yang sebanding. Dari dua input vektor yang menghasilkan suatu output ini kemudian ukuran jarak dihitung, membuat *Siamese Network* layak untuk digunakan dalam suatu proses klasifikasi jika salah satu dari dua vektor input diberi label (Koch, 2015).



Gambar 2. 5. Desain detail dari *Siamese Network*

Kedua jaringan saraf convolutional dibagi ke dalam bobot yang sama. Kemudian memproses data input dengan kualitas dan hasil yang sebelumnya tidak diketahui dimasukkan ke dalam suatu jaringan dan dibandingkan dengan data input dengan kualitas dan hasil yang sudah dikenali. Bergantung pada ukuran jarak yang ditentukan kesamaan dari kedua data input dihitung dan diprediksi kualitas dan hasil yang dapat dibuat (Koch, 2015).

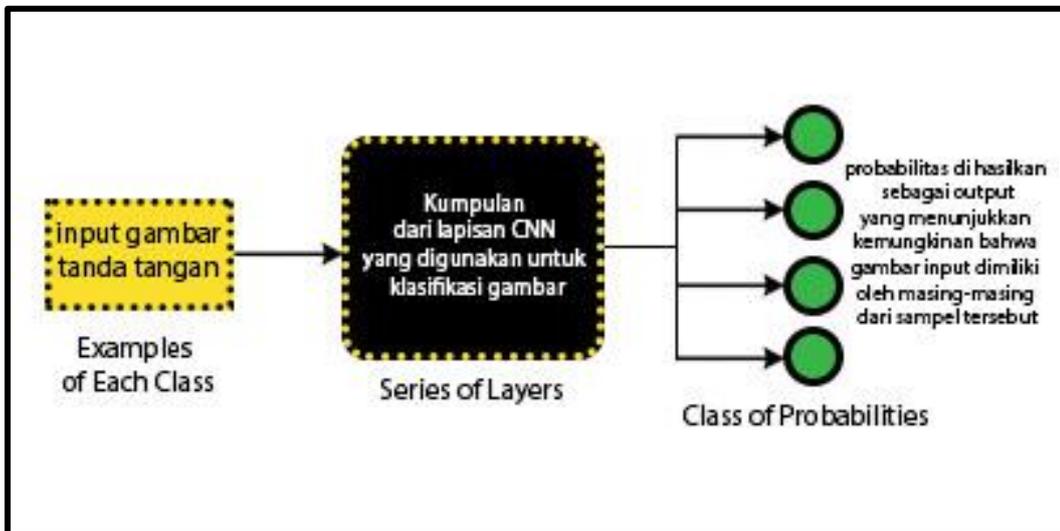
Pada Gambar 2.4 di lapisan terakhir dilakukan proses perbandingan output dari jaringan kembar dan membuat jarak kategori gambar yang sama menjadi 0 dan 1 untuk menghasilkan hasil yang berbeda. Fungsi perubahan kontras digunakan untuk tujuan ini (Hadsell et al., 2006):

$$L(W, Y, \vec{X}_1, \vec{Y}_1) = (1 - Y) \frac{1}{2} (D_W)^2 + (Y) \frac{1}{2} \left\{ \text{MAX}(0, m - D_W) \right\}^2 \quad (2. 1)$$

$$D_W = \sqrt{\{G_W(X_2) - G_W(X_1)\}^2} \quad (2. 2)$$

Rumus 2.1 dan rumus 2.2 merupakan rumus dari metode *Siamese Network* dimana D_W adalah lambang dari output jarak yang dihasilkan oleh jaringan, Y adalah nilai ril, (0/1) dan m adalah parameter yang nilainya ditentukan oleh jarak maksimum yang dipilih (1). G_W adalah output dari salah satu jaringan kembar. X_1 dan X_2 adalah pasangan data input (Hadsell et al., 2006).

Klasifikasi yang digunakan dalam metode *Siamese Network* menggunakan klasifikasi *One Shot* (satu tembakan) bukan menggunakan klasifikasi standar. Gambar 2.6 merupakan gambaran dari klasifikasi standar (indriati, 2020).



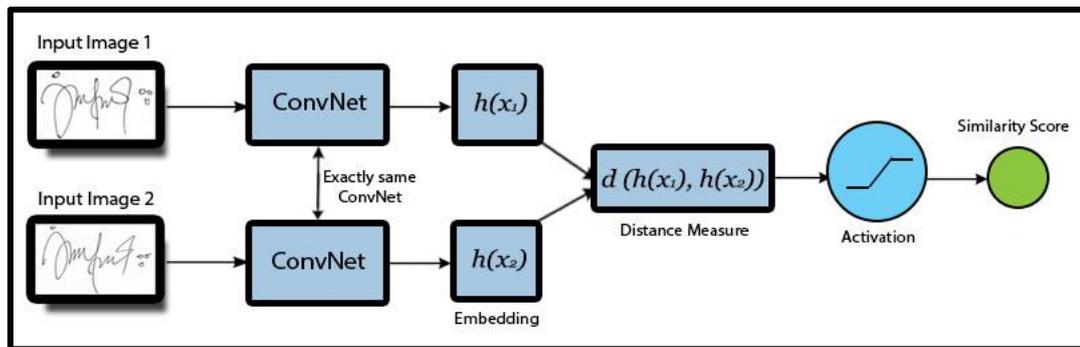
Gambar 2. 6. *Klasifikasi Standar*

Terdapat kekurangan pada klasifikasi standar diantaranya:

- a. Membutuhkan gambar dalam jumlah yang sangat banyak pada setiap kelas yang akan dilatih
- b. Tidak dapat menguji gambar dari kelas lain dengan jaringan yang sudah dilatih sebelumnya pada kelas yang ditentukan.
- c. Diperlukan proses training kembali untuk penambahan kelas atau gambar baru.

Salah satu cara untuk mengatasinya adalah menggunakan klasifikasi *One-shot Learning*. Alasan dinamai *one-shot* (Satu tembakan) adalah karena jaringan dapat belajar dengan cepat meskipun hanya ada satu gambar pelatihan. Pembelajaran One Shot bertujuan untuk mempelajari informasi tentang kategori dari satu atau beberapa sample gambar.

Jika menggunakan klasifikasi *One-shoot Learning* pada Gambar 2.7 menunjukkan ada 2 input gambar, gambar 1 dan gambar 2 akan diperiksa kemiripannya yang akan ditanamkan pada $h(x)$ yang berfungsi untuk mengukur jarak kemiripan gambar, jika gambar memiliki nilai jarak yang kecil maka akan dikategorikan *similar* (serupa) atau *dissimilar* (berbeda) (indriati, 2020).



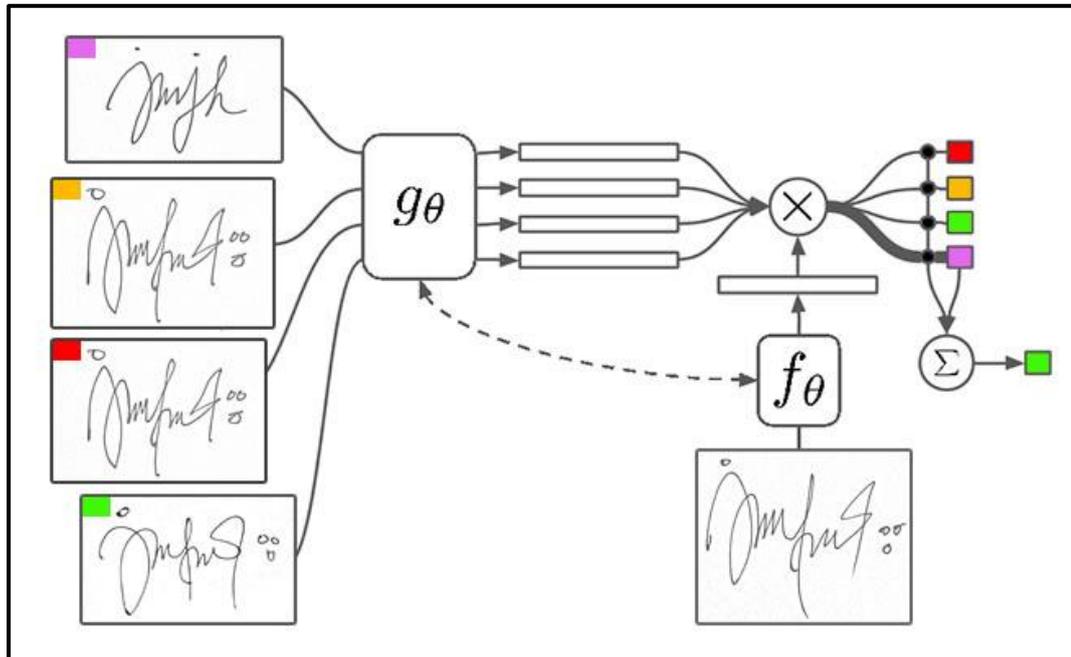
Gambar 2. 7. *Klasifikasi One-shoot Learning*

Penerapan *One-shoot Learning* pada metode *Siamese Network* menjalankan perannya seperti (indriati, 2020):

- a. Otak manusia tidak memerlukan ribuan gambar untuk mengklasifikasi dan mengidentifikasi suatu objek.
- b. *Siamese Network* adalah jenis khusus dari jaringan syaraf yang belajar untuk membedakan antara dua input dan mengklasifikasikannya.

Gambar 2.8 merupakan penerapan *One-shoot Learning* pada klasifikasi tanda tangan. Masing-masing tanda tangan dilambangkan dengan beberapa warna, tanda tangan pola ke-1 dengan warna ungu, tanda tangan pola ke-2 dengan warna orange, tanda tangan pola ke-3 dengan warna merah, tanda tangan pola ke-4

dengan warna hijau. Dari 4 pola tanda tangan yang berbeda kemudian akan diproses dengan one-shoot dan akan diuji dengan satu gambar uji. Output yang dihasilkan menunjukkan kemiripan pada tanda tangan pola ke-4 dengan warna hijau (indriati, 2020).



Gambar 2. 8. Penerapan One-shoot Learning pada metode Siamese Network