

PENGENALAN MANUSIA BERBASIS PADA SINGLE-GAIT MENGGUNAKAN METODE MODIFIKASI LATENT CONDITIONAL RANDOM FIELD (L-CRF)

HUMAN RECOGNITION BASED ON SINGLE-GAIT USING LATENT CONDITIONAL RANDOM FIELD (L-CRF) MODIFICATION METHOD

Aldo Tripolyta¹, Suryo Adhi Wibowo, S.T., M.T., Ph.D.², Rissa Rahmania, S.T., M.T.³

^{1,2,3}Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

¹aldotripolyta.pb3@gmail.com, ²suryoadhiwibowo@telkomuniversity.ac.id,

³saniarahmani@telkomuniversity.ac.id

Abstrak

Pengenalan *gait* merupakan salah satu bagian dari *computer vision* yang berfungsi untuk mengenali subjek (manusia) dengan jarak tertentu tanpa memperhatikan aspek biometrik seperti iris, wajah, dan sidik jari. *Latent Conditional Random Field* (L-CRF) merupakan salah satu algoritma pengenalan *single-gait* dengan hasil yang lebih baik. Walaupun hasil performansi akurasi subjek dengan kondisi berjalan normal (#NM) yang lebih baik, tapi masih terdapat masalah performansi akurasi terhadap kondisi berjalan lain seperti membawa tas (#BG) dan memakai jas (#CL). Modifikasi *Latent Conditional Random Field* (mL-CRF) merupakan salah satu metode yang masih berkaitan dengan L-CRF, tapi memiliki perbedaan pada parameter *pairwise*. Keunggulannya adalah hasil yang lebih baik dalam melatih dan menguji data dari domain yang identik. Penelitian ini menggunakan *silhouette frames* pada *data set CASIA gait database B* yang berisi 124 subjek dengan 110 *sequence* tiap subjek. Proses pengolahan data mL-CRF dilakukan berdasarkan sampel *training* (LT74 & MT62) dan 11 sudut pengamatan yang akan dibandingkan dengan L-CRF tanpa modifikasi, serta penelitian-penelitian sebelumnya. Pada penelitian ini, LT74 pada mL-CRF merupakan sampel *training* yang paling baik yang menghasilkan peningkatan akurasi sebesar 0,89% (#NM), 1,32% (#BG), 1,54% (#CL) terhadap L-CRF tanpa modifikasi.

Kata Kunci: *Gait, CASIA-B, L-CRF, silhouette frames.*

Abstract

Gait recognition is a part of computer vision that serves to recognize a subject (human) with a certain distance without regard to biometric aspects such as iris, face, and fingerprint. Latent Conditional Random Field (L-CRF) is one of the single-gait recognition algorithms with better results. Although the results of the accuracy of the subject's performance with normal running conditions (#NM) are better, but there are still problems in the accuracy of performance with other running conditions such as carrying a bag (#BG) and wearing a coat (#CL). Latent Conditional Random Field (mL-CRF) modification is one method that is still related to L-CRF, but has differences in pairwise parameters. Its advantages are better results in training and testing data from identical domains. This study uses the silhouette frames in the CASIA data set linked to the B database containing 124 subjects with 110 sequences per subject. The processing of mL-CRF data is done based on training samples (LT74 & MT62) and 11 observation angles that will be compared with L-CRF without modification, as well as previous studies. In this study, the LT74 on mL-CRF was the best training sample which resulted in an increase in accuracy of 0.89% (#NM), 1.32% (#BG), 1.54% (#CL) against L-CRF without modification.

Keyword : *Gait, CASIA-B, L-CRF, silhouette frames.*

1. Pendahuluan

Kemajuan biometrik dalam penggunaan di berbagai lingkup pekerjaan telah menciptakan sebuah tantangan baru untuk para peneliti. Salah satu contoh penggunaan biometrik adalah *gait*

recognition atau pengenalan gaya berjalan. Pengenalan *gait* merupakan cara mengenali dari satu individu yang menghasilkan tampilan data mentah berupa gambar sebagai inputnya [1]. Terdapat masalah terhadap performansi berupa akurasi [2], pada objek yang menempel atau menghalangi individu sebagai input seperti tas berdimensi besar, jas tebal, dan lain-lain.

Banyak metode yang telah digunakan untuk menguji performansi pengenalan *gait* pada seperti *Linear Discriminant Analysis* (LDA) [3]. Pada [4], penulis menggunakan pergerakan *co-clustering*. M. Alotaibi dan A. Mahmood menggunakan banyak *layer* pada *Deep Convolutional Neural Network* (CNN) [5] dan menghasilkan performansi yang lebih baik pada beberapa skenario permasalahan [6]. Kemudian, menggunakan *Gait Energy Image* (GEI) sebagai *data set* yang dimasukkan pada CNN sehingga mendapat nama baru GEINet [7].

Penulis mengusulkan algoritma sebuah pengenalan *single-gait* pada modifikasi model *Latent Conditional Random Field* (L-CRF). Metode ini menggunakan L-CRF sebagai tahap untuk mengekstraksi ciri yang merupakan tahapan penting dalam mendapatkan performansi yang baik. L-CRF dapat menangkap ciri tunggal dari perubahan gerakan yang dinamis dan perubahan gerak tingkah laku dari seseorang [8]. Dengan demikian, penulis menggunakan metode L-CRF yang bertujuan untuk mendapatkan hasil akurasi lebih baik dari penelitian sebelumnya seperti [4], Deep CNNs [9], dan *Invariant Feature Extraction* [10].

2. Konsep Dasar

2.1 Algoritma Pengenalan Gait

Algoritma pengenalan *gait* adalah cara yang dirancang untuk mengenali *gait* dari subjek manusia. Cara ini telah banyak digunakan dalam bidang *computer vision* dalam beberapa tahun ini, khususnya mengenai permasalahan biometrik. Terdapat dua klasifikasi kelas pada pengenalan *gait*, yaitu metode berbasis model untuk memodelkan parameter yang berisi persendian manusia dan model bebas yang mengabaikan pemodelan struktur yang mendasari *gait* untuk menganalisis urutan *gait* [2].

Normalnya, pengenalan *gait* akan mudah dikenali jika tidak banyak benda yang terpakai & berada di sekitar subjek. Namun, pada kenyataannya banyak benda yang menghalangi tubuh subjek sehingga menyulitkan dalam proses ekstraksi ciri. Terdapat beberapa proses pengenalan *gait* secara umum [12], seperti prapengenalan terdiri atas pengambilan data untuk input hingga filter *morphological*. Kemudian, pascapengenalan yaitu hasil berupa akurasi.

2.2 Data Set CASIA Gait Database B

Data set CASIA *gait database* B merupakan kumpulan data yang dikumpulkan dengan subjek *gait*. *Data set* ini berisi 124 *gait* dengan informasi berupa jenis kelamin, 31 wanita (F) dan 93 pria (M), serta tinggi badan ((H) dalam cm) yang terdiri dari tiga skenario yaitu normal (#NM), membawa tas (#BG), dan memakai jas (#CL) yang dapat diunduh secara gratis [11]. Selain itu, *data set* ini berupa *silhouette frame* yang memudahkan diolah pada *software* pemrosesan gambar.

2.3 Latent Conditional Random Field (L-CRF)

Latent Conditional Random Field (L-CRF) merupakan sebuah metode berbasis model untuk pengenalan *gait*. L-CRF merupakan pembaharuan dari *Conditional Random Field* (CRF) yang memiliki keunggulan hasil yang lebih baik dalam melatih dan menguji data dari domain yang identik. Selain itu, L-CRF memiliki dua tahapan, yaitu tahapan *training* yang melatih model CRF menggunakan data latih dan tahapan ekstraksi yang menggunakan model untuk dipakai mengekstraksi komponen dari domain data yang tidak memiliki label [13]. Terdapat juga langkah untuk mengetahui peluang ada atau tidaknya sebuah objek dalam model L-CRF [14].

2.4 Silhouette Frames

Silhouette frames merupakan ciri untuk mengenali *single-gait*. Bentuk lain dari *silhouette frames* adalah *Gait Energy Image* (GEI) dapat diartikan juga sebagai representasi dari *spatio-temporal* dari sebuah *gait* [15]. Selain itu, *silhouette frames* yang telah banyak digunakan khususnya untuk topik penelitian pengenalan *gait*. Salah satu *data set* yang menyediakan data *silhouette frames* terbesar kedua untuk *single-gait* [2], yaitu *data set* CASIA *gait database* B [11].

2.5 Teori Hitam dan Putih

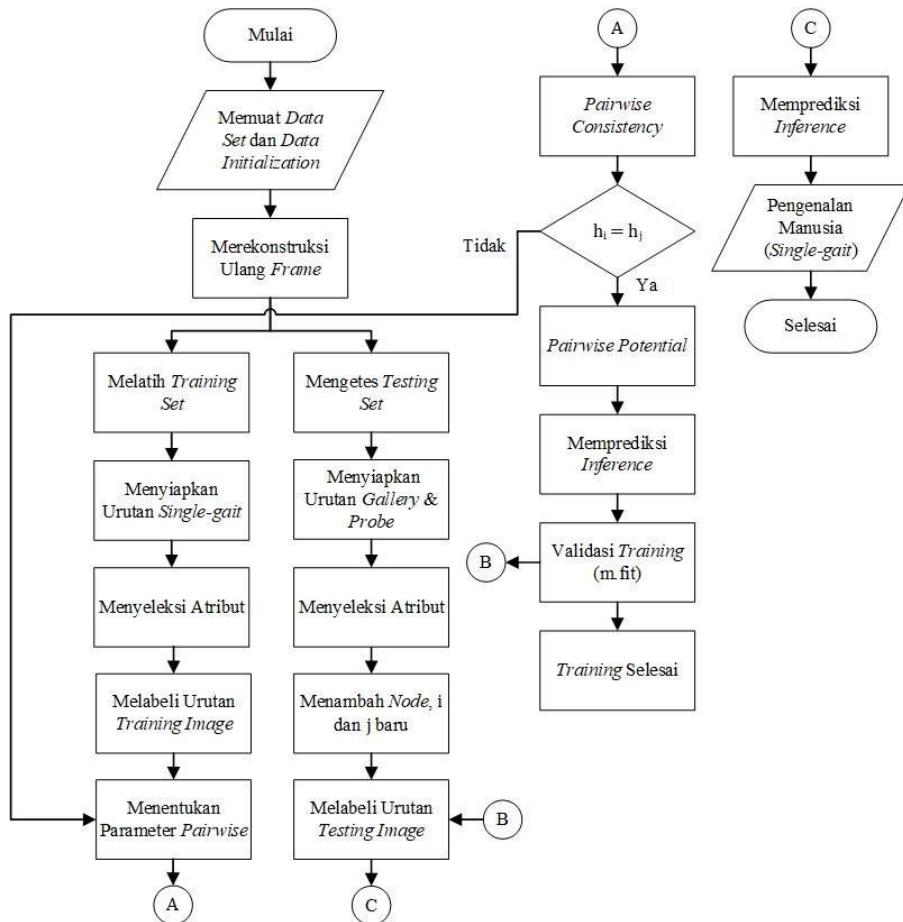
Teori hitam dan putih merupakan cara untuk menjelaskan bahwa sebuah media berupa gambar terdiri atas dua komponen warna, yaitu hitam dan putih. Terdapat dua proses pencampuran warna untuk mendapatkan warna hitam dan putih melalui *subtractive colors* dan *additive colors* [16]. Warna Hitam merupakan hasil dari perpaduan *subtractive colors* yang terdiri atas warna biru kehijauan (*cyan*), merah keunguan (*magenta*), kuning (*yellow*) atau dapat dikenal sebagai CMY. Sedangkan, warna putih adalah produk pencampuran dari *additive colors* yang terdiri atas warna

merah (*red*), hijau (*green*), dan biru (*blue*) atau dapat disebut sebagai RGB. Selain itu, warna hitam dan putih tidak dapat disebut sebagai *gray scale* karena komponen *encoding*-nya berbeda. *Trichromatic color Red-Green-Blue* (RGB) dapat mengodekan pada sistem grafis yang biasanya menggunakan tiga *bytes* yang memungkinkan $(28)^3 = 16.777.216$ kode warna berbeda [17].

3. Pembahasan

3.1 Desain Sistem

Pada tugas akhir ini dibuat desain sistem pengenalan *single-gait* dengan input data berupa gambar dengan jenis *silhouette frames*. Data set memakai CASIA gait database B. Kemudian, metode yang dipakai adalah modifikasi L-CRF.



Gambar 1. Diagram alir sistem.

3.2 Parameter Performansi

Parameter performansi merupakan pengujian algoritma pengenalan *single-gait* dengan parameter bantu yang telah ditentukan dalam proses sebelumnya. Adapun parameter performansi yang digunakan adalah akurasi. Akurasi merupakan salah satu pengujian yang menggunakan 11 sudut berbeda berdasarkan data set CASIA gait database B, yaitu $0^\circ, 18^\circ, 36^\circ, 54^\circ, 72^\circ, 90^\circ, 108^\circ, 126^\circ, 144^\circ, 162^\circ$, dan 180° . Persamaan (1) untuk menentukan *pairwise consistency*; persamaan (2) merupakan *pairwise potential* yang berfungsi untuk memodelkan kejadian-kejadian yang saling terkait pada *node* seperti \diamond dan \diamond dengan menangkap struktur domainnya; dan persamaan (3) merupakan *inference* untuk memprediksi urutan label yang paling mungkin terjadi.

$$\begin{aligned}
 & \text{Diagram showing a circular domain with nodes } \diamond_1, \diamond_2, \dots, \diamond_n. \text{ A central node } \diamond_{ij} \text{ is connected to nodes } \diamond_i \text{ and } \diamond_j. \text{ A condition } h_{ij} = h_{ij} \text{ is shown above the diagram.} \\
 & \text{Equation (1): } \Phi_{ij}(\diamond_i, \diamond_j | \diamond_{ij}, \diamond_{ij}) = \begin{cases} + & \text{if } h_{ij} = h_{ij} \\ - & \text{otherwise} \end{cases} \quad (1)
 \end{aligned}$$

$$\frac{\partial}{\partial h_{\phi}} \cdot \nabla \Phi(\Phi(h_{\phi})), (\Phi(h_{\phi})) \quad \text{jika } h_{\phi} \neq h_{\phi}$$

dengan $\Delta_{ij}(\Phi_i, \Phi_j, \Phi_k)$ merupakan sebuah kesamaan pada *pairwise consistency* untuk mengukur atribut untuk tuk yang terpilih dan kesamaan pada *pairwise consistency* adalah fungsi dua melakukan komputasi jarak sebesar Φ^2 ; Φ_i dan Φ_j merupakan vektor bobot; $\Phi_i = (\Phi_{i+}, \Phi_{i-})$

Φ_i merupakan konstanta *bias term*; $\Phi_i(\Phi_j)$ atau $\Phi_i(\Phi_k)$ adalah atribut yang menempati daerah atau Φ_i ; dan h atau h merupakan label kelas [2].

$$\exp((\Phi_i(\Phi_j), \Phi_i(\Phi_k))^T \Phi_{ij} \Phi_{ik})$$

$$\phi(\Phi_i, \Phi_j, \Phi_k; \Phi) = \frac{\exp((\Phi_i(\Phi_j), \Phi_i(\Phi_k))^T \Phi_{ij} \Phi_{ik})}{\sum_{\Phi_{ij}, \Phi_{ik}=0}^p}$$

dengan $\phi(\Phi_i, \Phi_j, \Phi_k; \Phi)$ adalah *feature* yang digabungkan (*concatenated*); *feature* gambar

ditunjukkan pada $\Phi_i(\Phi_j)$ dan $\Phi_i(\Phi_k)$; Φ merupakan parameter spesifik yang dihubungkan pada Φ_{ij} dan Φ_{ik} parameter (pembeda) kombinasi dari bagian label dan Φ adalah tipe *feature pairwise* dan bagian dari label di setiap kombinasinya [14]. Sedangkan, komponen ι merupakan

$$\Phi = \arg \max_{\Phi} \Phi(\Phi | \Phi, \Phi), \quad (3)$$

dengan Φ merupakan label yang sesuai dengan probabilitas maksimum; $\Phi(\Phi | \Phi, \Phi)$ merupakan komputasi marginal [18]; dan *argmax* merupakan domain fungsi pada nilai fungsi yang dimaksimalkan

Selain itu, hal yang perlu diperhatikan juga adalah kondisi berjalan seperti normal (#NM), menggunakan tas (#BG), dan menggunakan jas tebal (#CL). Artikel #NM dalam *data set* yang digunakan adalah #NM no. 5 dan 6, #BG no. 1 dan 2, serta #CL no. 1 dan 2. Kemudian, langkah selanjutnya adalah melakukan *training set* dengan dua sampel, yaitu LT74 berisi 74 subjek (manusia) dan MT62 memiliki 62 subjek. Perhitungan akurasi yang berbasis pada probabilitas dengan *mapping* antara urutan dari observasi $\Phi = \{\Phi_1, \Phi_2, \dots, \Phi_m\}$ dan observasi label Φ

$= \{\Phi_1, \Phi_2, \dots, \Phi_m\}$ dapat dilihat pada persamaan (4).

$$P(\Phi | \Phi, \Phi) = \sum_h P(\Phi | \Phi, h, \Phi) P(h | \Phi, \Phi), \quad (4)$$

dengan $P(\Phi | \Phi, \Phi)$ merupakan rate akurasi berbasis *conditional model*; $\Phi = \{\Phi_1, \Phi_2, \dots, \Phi_m\}$ merupakan label yang diobservasi; $h = \{h_1, h_2, \dots, h_m\}$ merupakan urutan yang tidak diobservasi; dan $\{\Phi_1, \Phi_2, \dots, \Phi_m\}$ adalah urutan yang diobservasi dengan mengambil nilai kontinu/diskret [18].

Faktor yang mempengaruhi hasil perbandingan akurasi pada sampel *training* dan sudut akan diuraikan berdasarkan parameter estimasi [19]. Sampel *training* dipengaruhi oleh *parallelism* dan *approximate training*. Hasil akurasi sudut dipengaruhi oleh *implementation concerns*, *maximum likelihood*, dan *stochastic gradient methods*.

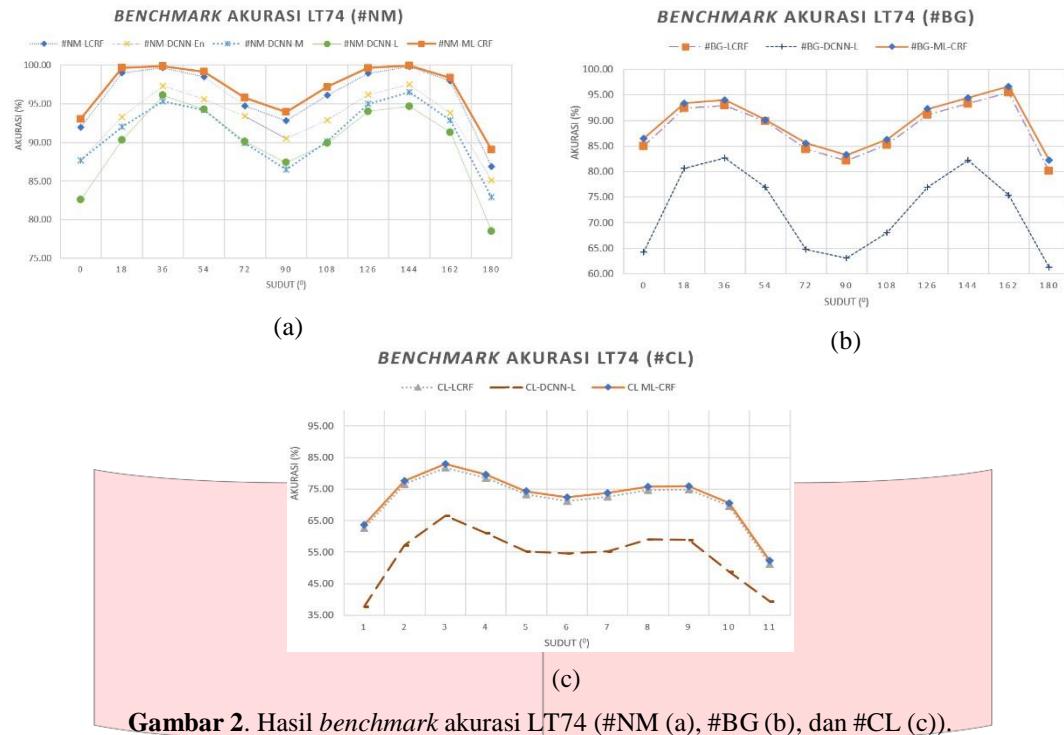
3.3 Hasil Sistem

Hasil simulasi sistem terbagi menjadi 2 sampel *training*. Pertama, *large training* (LT) yang memiliki sampel *training* sebanyak 74 subjek (manusia) atau 60% dari seluruh *data set* CASIA

gait database B sebesar 124 subjek (manusia). Kedua, *medium training* (MT) yang berisi 62 subjek (manusia) atau 50% sebagai sampel *training*-nya. Keseluruhan sampel *training* mencakup 11 sudut sebagai parameter yang membedakan subjek satu dengan lainnya.

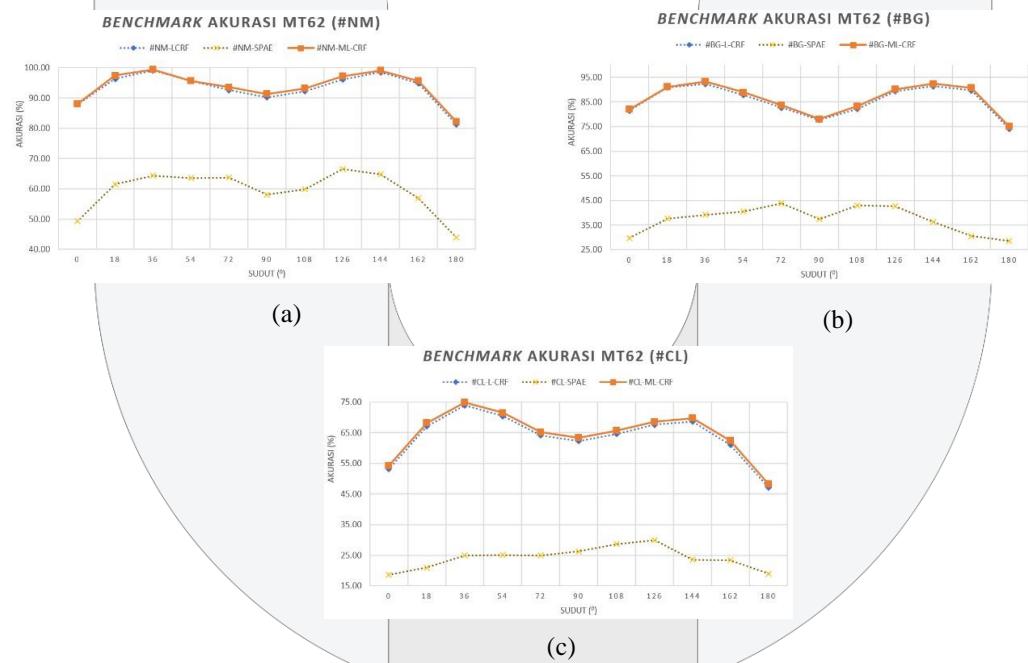
1. LT74 dengan Subjek (Manusia) Sebanyak 74

Melalui Gambar 2, dapat diketahui akurasi LT74 dengan modifikasi pada L-CRF mengalami beberapa kenaikan nilai terhadap metode lainnya. Pada kondisi berjalan #NM, modifikasi L-CRF mengalami kenaikan 0,85 poin terhadap L-CRF tanpa modifikasi; 3,86 poin terhadap DCNN-En; 5,70 poin terhadap DCNN-M; dan 6,96 poin terhadap DCNN-L. Kemudian, kondisi berjalan #BG, modifikasi L-CRF mengalami kenaikan 1,16 poin terhadap L-CRF tanpa modifikasi dan 17,14 poin terhadap DCNN-L. Pada #CL, modifikasi L-CRF mengalami kenaikan sebesar 1,10 poin terhadap L-CRF tanpa modifikasi dan 18,62 poin terhadap DCNN-L. Jadi, tren kenaikan modifikasi L-CRF berlaku terhadap seluruh metode.

**Gambar 2.** Hasil *benchmark* akurasi LT74 (#NM (a), #BG (b), dan #CL (c)).

2. MT62 dengan Subjek (Manusia) Sebanyak 62

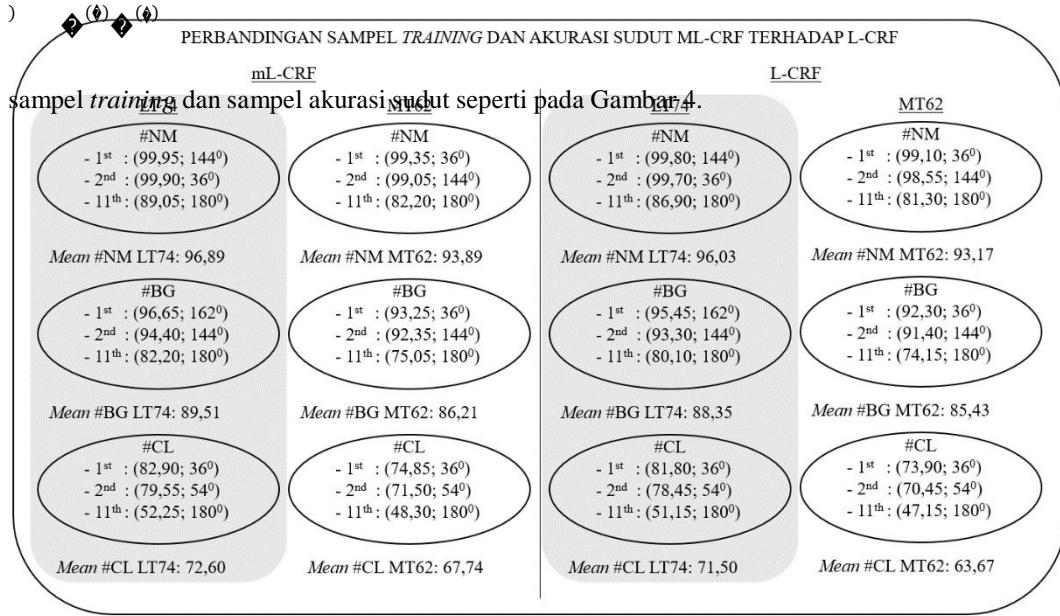
Melalui Gambar 3, dapat diketahui akurasi MT62. Modifikasi pada L-CRF mengalami beberapa kenaikan nilai terhadap metode lainnya. Pada kondisi berjalan #NM, modifikasi L-CRF mengalami kenaikan 0,72 poin terhadap L-CRF tanpa modifikasi; 34,55 poin terhadap *Stacked Progressive Auto-Encoders* (SPAЕ). Kemudian, kondisi berjalan #BG, modifikasi L-CRF mengalami kenaikan 0,78 poin terhadap L-CRF tanpa modifikasi dan 48,98 poin terhadap SPAЕ. Pada #CL, modifikasi L-CRF mengalami kenaikan sebesar 1,07 poin terhadap L-CRF tanpa modifikasi dan 40,57 poin terhadap SPAЕ. Dengan demikian, tren kenaikan modifikasi L-CRF berlaku terhadap seluruh metode.

**Gambar 3.** Hasil *benchmark* akurasi MT62 (#NM (a), #BG (b), dan #CL (c)).

3.4 Analisis Sistem

Bagian ini menjelaskan faktor yang mempengaruhi parameter performansi. Terdapat lima faktor yang mempengaruhi hasil sistem. Kelima faktor tersebut parameter estimasi [19], antara lain pada perbandingan akurasi sampel *training* dipengaruhi oleh *parallelism* dan *approximate training*. Kemudian, pada perbandingan sampel akurasi sudut dipengaruhi oleh *implementation concerns*, *maximum likelihood*, dan *stochastic gradient methods*. Variasi sudut yang dihasilkan pada sistem disebabkan oleh *conditional likelihood* $p(\Phi_i | \Phi_j; \Theta)$ dengan setiap $\Phi_i = \{\Phi_1^{(t)}, \Phi_2^{(t)}, \dots, \Phi_{11}^{(t)}\}$ yang merupakan urutan input pada data pelatihan $D = \{\Phi^{(t)}, \Theta^{(t)}\}_{t=1}^n$. Kejadian (Φ)

tersebut mengakibatkan perbedaan antara akurasi sudut satu dengan lainnya dengan setiap $\Phi_i = \{\Phi_1^{(t)}, \Phi_2^{(t)}, \dots, \Phi_{11}^{(t)}\}$ merupakan urutan dari *inference*-nya. Perbandingan dilakukan berdasarkan



Gambar 4. Perbandingan sampel *training* & akurasi sudut mL-CRF terhadap L-CRF.

1. Pengaruh *Parallelism*

Parallelism merupakan keadaan yang memiliki *feature* sama dan mendukung komputasi paralel (*parallel computing*). Komputasi ini memiliki karakteristik seperti perintah yang didapat dari pembagian instruksi dapat dijalankan secara bersamaan dengan menggunakan prosesor yang berbeda, serta dapat menyelesaikan masalah komputasi dengan membagi secara bersamaan (simultan) menjadi bagian-bagian yang terpisah. Pada *parallelism*, terdapat turunan gradien stokastik yang memiliki fungsi untuk mempercepat perhitungan gradien sebagai optimasinya.

2. Pengaruh *Approximate Training*

Approximate training menyatakan bahwa grafik struktur L-CRF dapat menghitung fungsi partisi $\Phi(\Phi)$ dan distribusi marginal $p(\Phi_i | \Phi_j)$. Kedua perhitungan tersebut memiliki peran dalam proses pelabelan urutan. Apabila struktur grafis lebih kompleks. Maka, marginal distribusi dan fungsi partisi tidak dapat dihitung dengan rapi.

3. Pengaruh *Implementation Concerns*

Implementation concerns merupakan cara untuk memberikan gambaran mengenai skala masalah yang terjadi pada L-CRF seperti nilai tipikal/khas untuk jumlah fitur dan waktu pelatihan. Untuk masing-masing *data set* memiliki jumlah parameter dalam L-CRF yang terlatih (*trained*), ukuran *training set*, jumlah label, dan waktu pelatihan. Pada kasus ini jumlah label adalah hal yang paling mempengaruhi waktu pelatihan.

4. Pengaruh *Maximum Likelihood*

Maximum likelihood merupakan cara untuk melatih L-CRF dengan pemilihan parameter untuk performansi akurasi tiap sudut sehingga data pelatihan memiliki probabilitas tertinggi di bawah model. Parameter *maximum likelihood* bisa ditemukan oleh prosedur optimasi numerik yang memanggil inferensi algoritmanya. Algoritma inferensi digunakan untuk menghitung nilai *likelihood* dan gradiennya. Selain itu, *likelihood* adalah fungsi optimalisasi yang menyatu dengan solusi optimal dalam akurasi sudut.

5. Pengaruh *Stochastic Gradient Methods*

Stochastic gradient method adalah metode optimisasi akurasi yang dirancang untuk memanfaatkan setiap iterasi untuk memilih sampel pelatihan secara acak. Kemudian, gradien memberikan sampel untuk mengambil langkah selanjutnya dalam penentuan arah (*direction*). Pada pengaturan *batch*, arah *stochastic gradient* dapat dihitung lebih cepat meskipun perlu dilakukan penyetelan (*tuning*) secara tepat. Selain itu, dalam setiap iterasi L-CRF, *stochastic gradient* memilih sampel pelatihan ($\diamond^{(t)}$, $\diamond^{(t)}$) secara acak.

4. Kesimpulan

Algoritma pengenalan *single-gait* dengan metode modifikasi *Latent Conditional Random Field* (L-CRF) telah diimplementasikan untuk menentukan ciri *single-gait* yang stabil dari data latih. Setelah melakukan proses simulasi dan mendapatkan hasil, serta analisisnya. Maka, penulis mendapatkan kesimpulan sebagai berikut.

1. Parameter performansi LT74 mengalami peningkatan mean akurasi pada #NM sebesar 0,89% terhadap L-CRF tanpa modifikasi; 4,15% terhadap DCNN-En; 6,25% terhadap DCNN-M; 7,74% terhadap DCNN-L; #BG sebesar 1,32% terhadap L-CRF tanpa modifikasi; 23,68% terhadap DCNN-L; dan #CL sebesar 1,54% terhadap L-CRF tanpa modifikasi; 34,49% terhadap DCNN-L.
2. Parameter performansi MT62 mengalami peningkatan mean akurasi pada #NM sebesar 0,77% terhadap L-CRF tanpa modifikasi; 58,24% terhadap SPAE; #BG sebesar 0,92% terhadap L-CRF tanpa modifikasi; 131,53% terhadap SPAE; dan #CL sebesar 1,68% terhadap L-CRF tanpa modifikasi; 167,91% terhadap SPAE.
3. Metode modifikasi *Latent Conditional Random Field* (L-CRF) lebih baik terhadap 8 *state-of-the-art* metode pengenalan *single-gait* pada *data set CASIA gait database B*.

Daftar Pustaka :

- [1] M. Babaee, L. Li, and G. Rigoll, "Gait Recognition from Incomplete Gait Cycle," *2018 25th IEEE Int. Conf. Image Process.*, pp. 768–772, 2018.
- [2] X. Chen, J. Weng, W. Lu, and J. Xu, "Multi-Gait Recognition Based on Attribute Discovery," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 40, no. 7, pp. 1697–1710, 2018.
- [3] X. Huang, N. V Boulougouris, and S. Member, "Gait Recognition With Shifted Energy Image and Structural Feature Extraction," *IEEE Trans. IMAGE Process.*, vol. 21, no. 4, pp. 2256–2268, 2012.
- [4] M. Hu, Y. Wang, Z. Zhang, J. J. Little, and D. Huang, "View-Invariant discriminative projection for multi-View gait-Based human identification," *IEEE Trans. Inf. Forensics Secur.*, vol. 8, no. 12, pp. 2034–2045, 2013.
- [5] W. Kusakunniran, Q. Wu, J. Zhang, H. Li, and L. Wang, "Recognizing gaits across views through correlated motion co-clustering," *IEEE Trans. Image Process.*, vol. 23, no. 2, pp. 696–709, 2014.
- [6] M. Alotaibi and A. Mahmood, "Improved Gait Recognition based on Specialized Deep Convolutional Neural Networks," *IEEE*, p. 1, 2015.
- [7] K. Shiraga, Y. Makihara, and D. Muramatsu, "GEINet : View-Invariant Gait Recognition Using a Convolutional Neural Network," *IEEE*, p. 1, 2016.
- [8] A. T. Schulz and R. Stiefelhagen, "Pedestrian Intention Recognition using Latent-dynamic Conditional Random Fields," *IEEE Intell. Veh. Symp.*, no. Iv, pp. 0–5, 2015.
- [9] Z. Wu, Y. Huang, L. Wang, X. Wang, and T. Tan, "A Comprehensive Study on Cross-View Gait Based Human Identification with Deep CNNs," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 2, pp. 209–226, 2017.
- [10] S. Yu, H. Chen, Q. Wang, L. Shen, and Y. Huang, "Invariant feature extraction for gait recognition using only one uniform model," *Neurocomputing*, vol. 239, pp. 81–93, 2017.
- [11] S. Yu, D. Tan, and T. Tan, "A Framework for Evaluating the Effect of View Angle , Clothing and Carrying Condition on Gait Recognition," *18th Int. Conf. Pattern Recognit.*, pp. 6–9,

- 2006.
- [12] A. Hayder, J. Dargham, A. Chekima, and G. M. Ervin, "Person Identification Using Gait," *Int. J. Comput. Electr. Eng.*, vol. 3 no. 4, no. August, pp. 477–478, 2011.
 - [13] Z. Chen and B. Liu, "Lifelong Machine Learning," 2nd ed., Morgan & Claypool, 2018, pp. 132–133.
 - [14] P. Schnitzspan and S. Roth, "Automatic Discovery of Meaningful Object Parts with Latent CRFs," *IEEE*, pp. 121–128, 2010.
 - [15] J. Han and S. Member, "Individual Recognition Using Gait Energy Image," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 28, no. 2, pp. 316–322, 2006.
 - [16] R. Szeliski, "Computer Vision - Algorithms and Applications," London: Springer, 2011, pp. 71–72.
 - [17] L. Shapiro and G. Stockman, "Computer Vision," Pearson, 2010, pp. 213–214.
 - [18] S. Neogi, M. Hoy, W. Chaoqun, and J. Dauwels, "Context Based Pedestrian Intention Prediction Using Factored Latent Dynamic Conditional Random Fields," *IEEE*, p. 3, 2017.
 - [19] C. Sutton and A. McCallum, "An Introduction to Conditional Random Fields," *Found. Trends Mach. Learn.*, vol. 4, no. 4, pp. 267–373, 2011.

