



INSYST

Journal of Intelligent System and Computation

p-ISSN: 2621-9220

e-ISSN: 2722-1962

Volume 3 Nomor 1, April 2021



Published By **Lembaga Penelitian dan Pengabdian Masyarakat (LPPM)**
Institut Sains dan Teknologi Terpadu Surabaya (ISTTS)
formerly **Sekolah Tinggi Teknik Surabaya (STTS)**



Managed By
Departement of Informatics
Institut Sains dan Teknologi Terpadu Surabaya (ISTTS)

INSYST

Journal of Intelligent System and Computation

Volume 03 Nomor 01 April 2021

Editor in Chief:

Dr. Yosi Kristian, S.Kom, M.Kom.
Institut Sains dan Teknologi Terpadu Surabaya, Indonesia

Managing Editor:

Dr. Esther Irawati Setiawan, S.Kom., M.Kom.
Institut Sains dan Teknologi Terpadu Surabaya, Indonesia

Reddy Alexandro H., S.Kom., M.Kom.
Institut Sains dan Teknologi Terpadu Surabaya, Indonesia

Editorial Board:

Dr. Ir. Endang Setyati, M.T.
Institut Sains dan Teknologi Terpadu Surabaya, Indonesia

Ir. Edwin Pramana, M.App.Sc, Ph.D
Institut Sains dan Teknologi Terpadu Surabaya, Indonesia

Prof. Dr. Ir. Mauridhi Hery Purnomo, M.T.
Institut Sepuluh November, Indonesia

Hindriyanto Dwi Purnomo, Ph.D.
Universitas Kristen Satya Wacana, Salatiga, Indonesia

Hendrawan Armanto, S.Kom., M.Kom.
Institut Sains dan Teknologi Terpadu Surabaya, Indonesia

Dr. Lukman Zaman PCSW, M.Kom.
Institut Sains dan Teknologi Terpadu Surabaya, Indonesia

Dr. Diana Purwitasari, S.Kom., M.Sc.
Institut Sepuluh November, Indonesia

Dr. Joan Santoso, S.Kom., M.Kom.
Institut Sains dan Teknologi Terpadu Surabaya, Indonesia

INSYST

Journal of Intelligent System and Computation

Volume 03 Nomor 01 April 2021

Reviewer:

Teguh Wahyono, S.Kom., M.Cs.

Universitas Kristen Satya Wacana, Salatiga, Indonesia

Dr. Anang Kukuh Adisusilo, ST, MT.

Universitas Wijaya Kusuma, Surabaya, Indonesia

Dr. I Ketut Eddy Purnama, ST., MT.

Institut Sepuluh November, Indonesia

Prof. Dr. Benny Tjahjono, M.Sc.

Coventry University, United Kingdom

Dr. Ir. Gunawan, M.Kom.

Institut Sains dan Teknologi Terpadu Surabaya, Indonesia

Dr. Umi Laili Yuhana S.Kom., M.Sc.

Institut Sepuluh November, Indonesia

Dr. Tita Karlita, S.Kom., M.Kom.

Politeknik Elektronika Negeri Surabaya, Indonesia

Dr. Ir. Rika Rokhana, M.T.

Politeknik Elektronika Negeri Surabaya, Indonesia

Dr. I Made Gede Sunarya, S.Kom., M.Cs.

Universitas Pendidikan Ganesha, Indonesia

Dr. Yuni Yamasari, S.Kom., M.Kom.

Universitas Negeri Surabaya, Indonesia

Dr. Adri Gabriel Sooai, S.T., M.T.

Universitas Katolik Widya Mandira, Indonesia

INSYST

Journal of Intelligent System and Computation

Volume 03 Nomor 01 April 2021

Daftar Isi

Deteksi Citra Pornografi Memanfaatkan Deep Convolutional Neural Network Kevin Setiono, Yosi Kristian, Gunawan	1
Disjoint Community Detection pada Network Kegiatan Kemahasiswaan di ISTTS Menggunakan Fast Greedy dan Walktrap Mikhael Setiawan, Gunawan, F.X. Ferdinandus	7
Deteksi Polisi Tidur pada Jalan Menggunakan Analisis Blob dan Konvolusional Neural Network Ervin Indra Nugraha, Yuliana Melita Pranoto	16
Deteksi Pemakaian Helm Proyek dengan Metode Convolutional Neural Network Bambang Widodo, Hendrawan Armanto, Endang Setyati	23
Pengukuran Material pada Bak Truk Berbasis Citra Reddy Alexandro Harianto	30
Stance Classification pada Berita Berbahasa Indonesia Berbasis Bidirectional LSTM Esther Irawati Setiawan, Ika Lestari	41
Ekstraksi Ulasan Sentimen Film dari Twitter dengan Naïve Bayes pada Situs Web Media Sosial Penggemar Film Adri Grabiël Sooi, Melania Laniwati	49

Deteksi Citra Pornografi Memanfaatkan Deep Convolutional Neural Network

Kevin Setiono, *Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya(ISTTS)*,
Yosi Kristian, *Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya(ISTTS)*,
Gunawan, *Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya(ISTTS)*.

Abstrak—Internet merupakan salah satu sumber informasi yang sangat mudah diakses dan sangat lengkap pada zaman sekarang ini. Dari banyaknya konten tersebut terdapat konten pornografi yang meresahkan dan memberikan dampak buruk pada perkembangan anak-anak. Hingga tahun 2020 pemblokiran konten pornografi menyumbang 70 persen dibandingkan konten negative lainnya. Metode untuk mencegah/memblokir konten pornografi ada berbagai macam mulai dari memblokir websitenya hingga mendeteksi berdasarkan citra yang ada. Penelitian ini akan mencoba mendeteksi citra pornografi dengan bantuan Deep Convolutional Neural Network. Pembuatan model menggunakan transfer learning hingga fine tuned fine transfer learning dan mencoba model-model state of the art. Penelitian ini menghasilkan model yang mampu mendeteksi citra pornografi dengan akurasi 78%. Selain memiliki akurasi yang cukup tinggi model ini juga mampu mendeteksi bagian-bagian intim dari wanita yang menjadi fitur dari citra pornografi. Kemampuan mendeteksi fitur tersebut telah diujicoba dengan mengubah model yang digunakan penelitian ini sebagai detektor objek pada citra pornografi.

Kata Kunci—Convolutional Neural Network, Deteksi Citra Pornografi, Deep Learning, EfficientNet.

I. PENDAHULUAN

Konten yang ada pada Internet saat ini sangatlah banyak dan lengkap. Banyaknya konten tersebut tidak dapat menjamin seluruh konten yang ada selalu konten positif. Konten pornografi merupakan konten negatif yang tersebar dengan luas dan dengan mudah ditemukan di Internet. Korban dari konten negatif internet dimulai dari anak di usia muda (11 hingga 13) tahun[1]. Dikarenakan permasalahan diatas masalah untuk melakukan deteksi pornografi menjadi salah satu hal yang penting dilakukan dalam penelitian Computer Vision maupun dalam bidang Machine Learning. Penelitian ini akan membahas lebih detail mengenai metode untuk melakukan deteksi dengan bantuan Machine Learning.

Di Indonesia yang memiliki jumlah penduduk lebih dari 264 juta jiwa, terdapat 171 juta jiwa yang menggunakan

Internet. Selama pertengahan tahun 2018 hingga awal tahun 2019 Kementerian Komunikasi dan Informatika telah melakukan pemblokiran situs dengan konten negatif. Hasilnya sebanyak 898.108 konten pornografi ditemukan dan berhasil di blok[2]. Jumlah konten pornografi ini merupakan konten yang terbanyak dari seluruh konten negatif yang ditemukan. Konten negatif tersebut meliputi Citra Pornografi, Hoaks, Fraud, penipuan online, radikalisme, perjudian, dan lain-lain. Pada penelitian ini fokus akan diarahkan pada deteksi citra pornografi.

Pornhub merupakan salah satu situs penyedia pornografi terbesar yang ada. Pornhub mengeluarkan ulasan sepanjang tahun 2019 pada blog Pornhub Insights[3]. Berdasarkan pencarian 5 kata kunci yang paling sering dicari oleh user adalah Japanese, Hentai, Lesbian, MILF, dan Korean. Sedangkan perbandingan jumlah penonton Pria mendominasi dengan angka 68% dibandingkan Wanita yang hanya 32% saja. Penonton Wanita banyak menonton genre Lesbian pada situs Pornhub.

Computer Vision dapat memfilter konten pornografi dengan mengambil citra yang tampil pada sebuah website dan mengolahnya. Deteksi dengan menggunakan Computer Vision sendiri secara umum dapat dibagi ke dalam dua bagian yaitu dengan menggunakan Neural Network dan tanpa menggunakan Neural Network/Machine Learning. Selain untuk mendeteksi citra pornografi Deep Convolutional Neural Network (DCNN) juga telah digunakan untuk mengklasifikasi tekstur serat kayu pada citra mikroskopik[4] dan mengklasifikasi post Kesehatan[5].

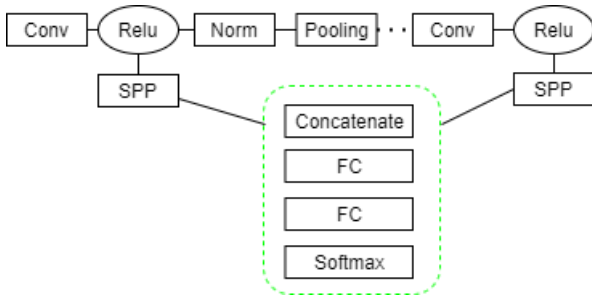
Penelitian deteksi citra pornografi telah dilakukan sejak cukup lama. Metode yang digunakan untuk deteksi pornografi juga bermacam-macam. Cara yang umum digunakan pada Indonesia ialah dengan melakukan filter pada tautan yang akan diakses oleh pengguna[6]. Hal ini membuat pengguna tidak dapat mengakses website-website yang mengandung konten pornografi.

Banyak metode dilakukan oleh peneliti yaitu dengan menggunakan penelitian berbasis warna. Warna dapat dijadikan salah satu metode untuk mendeteksi pornografi karena pada citra pornografi banyak menampilkan bagian yang menunjukkan warna kulit[7]. Metode ini dilakukan oleh beberapa peneliti terdahulu. Cara lain yang dilakukan untuk mendeteksi dengan menggunakan color histogram[8]. Perkembangan lain dengan menggunakan basis warna

Kevin Setiono, Departemen Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail: kevinsetiono@stts.edu)

Yosi Kristian, Departemen Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail: yosi@stts.edu)

Gunawan, Departemen Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail: gunawan@stts.edu)



Gambar. 1. Multi Level Feature Framework

adalah dengan menggabungkan deteksi wajah dengan deteksi warna kulit dikarenakan area pornografi pada tubuh memiliki karakteristik yang hampir sama dengan wajah[9].

Metode yang digunakan untuk mendeteksi citra pornografi juga mengalami pergeseran seiring perkembangan dari computer vision dan machine learning. Wang[10] melakukan deteksi pornografi dengan menggunakan CNN dengan sifat strongly supervised. Li[11] melakukan penelitian dengan memanfaatkan CNN untuk mendapatkan fitur dari citra kemudian mengolah hasil tersebut menjadi detektor pornografi. Ganguly[12] menggunakan CaffeNet untuk deteksi citra dengan intensi pornografi.

Kontribusi yang diberikan oleh penulis melalui penelitian ini adalah sebagai berikut :

- Membuat dataset untuk citra pornografi
- Membuat model yang mampu mendeteksi citra pornografi dengan akurasi tinggi dan resource seminimal mungkin
- Merancang pipeline untuk mendeteksi citra pornografi


II. PENELITIAN TERKAIT

Citra pornografi harus didefinisikan untuk mempermudah dalam penentuan citra yang tergolong pornografi dan mana yang tidak. Definisi citra pornografi diambil dari penelitian milik Wang[10], dimana pada sebuah citra pornografi adalah citra yang menampilkan salah satu organ intim secara eksplisit. Definisi ini membantu penentuan dalam pembuatan dataset citra pornografi pada penelitian ini.

Kemampuan dari Deep Convolutional Neural Network untuk mendeteksi fitur dari citra pornografi juga sebelumnya telah dicoba pada penelitian Li. Li[13] membuat CNN untuk mengekstrak fitur pornografi pada setiap layernya, kemudian fitur tersebut digunakan untuk menentukan sebuah citra merupakan pornografi atau tidak. Gambaran dari sistem yang dibuatnya dapat dilihat pada Gambar 1.

Dewantoro[14] membuat penelitian untuk mendeteksi puting pada payudara Wanita. Pada penelitian ini dia membuat pemeriksaan dalam beberapa tahapan, tahapan tersebut dilakukan karena ada kesamaan antara bagian tubuh manusia dengan wajah. Pada penelitian ini akan menggunakan juga kerangka tahapan yang digunakan dewantoro sebagai dasar dalam pembuatan hierarki dalam mendeteksi citra pornografi.

Perkembangan dari CNN mengalami kemajuan sangat pesat dimulai dari munculnya Alex-Net yang memiliki jumlah hidden layer lebih banyak. Semenjak ini mulailah perkembangan CNN yang semakin dalam hingga disebut



Gambar. 2. Sistem Deteksi Pornografi

Deep Convolutional Neural Network. Model-model yang akan dicoba diantaranya VGG16[15], ResNet[16], MobileNetV2[17] dan EfficientNet[18].

Beberapa model yang dicoba juga merupakan model yang state of the art, yaitu model yang memiliki hasil akurasi yang tinggi namun menggunakan jumlah resource yang kecil. Model ini adalah MobileNetV2 dan EfficientNet. Model yang diusulkan akan dibuat dengan menggunakan dasar dari model-model ini.


Selain menjadikan model ternama sebagai dasar pembuatan model, model-model ini juga akan dicoba dengan menggunakan metode transfer learning. Selain dengan menggunakan transfer learning akan dicoba juga dengan menggunakan salah satu metode transfer learning yaitu Fine Tuning. Fine tuning adalah salah satu metode yang sangat baik untuk membuat sebuah klasifier dari citra dari model yang telah ada dengan menggunakan dataset buatan sendiri.

III. SISTEM YANG DIAJUKAN

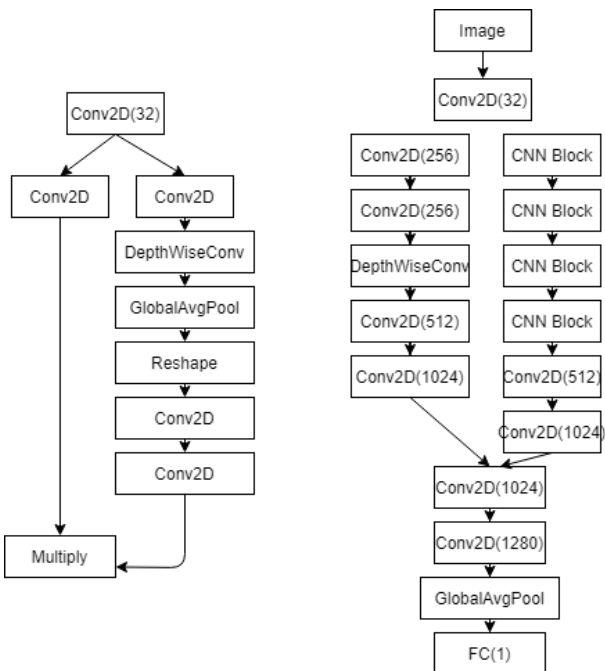
Penelitian ini mengusulkan pipeline sistem deteksi citra pornografi yang dapat dilihat pada Gambar 2. Pada pipeline ini dibuat beberapa tahapan untuk melakukan deteksi citra pornografi. Awalnya sebuah citra harus melalui proses deteksi wajah, penjelasan pentingnya deteksi wajah akan dijelaskan pada bagian III.A. Selanjutnya citra tersebut akan dideteksi dengan sistem cerdas berbasis Deep Convolutional Neural Network.

A. Face Detection

Citra pornografi memiliki karakteristik yang mirip dengan wajah. Hal ini sisi gelap terang dari citra pornografi hampir sama dengan wajah (terang, gelap dan terang). Untuk mengurangi kemungkinan wajah dideteksi pornografi maka pada sistem yang akan dirancang ini akan melakukan deteksi wajah setelah menerima inputan citra. Deteksi citra



Gambar. 3. DCNN Pertama yang Diusulkan



Gambar. 4. DCNN Kedua yang Diusulkan

wajah akan menggunakan Haarcascade. Citra yang memiliki proporsi sedikit maka akan dilanjutkan melalui proses deteksi pornografi.

B. Deteksi Pornografi

Bagian ini merupakan bagian yang akan menggunakan Deep Convolutional Neural Network. Deep Convolutional Network yang akan diuji coba meliputi Deep Convolutional Neural Network yang dibuat sendiri dan percobaan menggunakan CNN yang telah teruji. CNN yang akan dicoba tersebut adalah VGG16, ResNet-50, MobileNetV2, dan EfficientNet.

C. DCNN Usulan

DCNN buatan sendiri yang akan dicoba terdapat 2 macam : dibuat berbasis LeNet dan dibuat dengan menggunakan Residual Network. Detail dari DCNN pertama yang diusulkan dapat dilihat pada Gambar 2. Setiap blok pada



Gambar. 5. Citra Pornografi pada Dataset



Gambar. 6. Citra Pornografi pada Dataset Dieliminasi

network ini terdiri dari 3 buah Convolutional Layer, diharapkan 2 Convolutional Layer awal mencari fitur yang ada kemudian barulah oleh Convolutional layer ketiga untuk mengambil fitur yang menentukan pornografi. Layer terakhir menggunakan Fully Connected layer sebanyak satu karena activation dari DCNN ini menggunakan sigmoid.

DCNN kedua yang dicoba dibuat dengan menggunakan Residual Network. Tujuannya untuk memperdalam network akan dapat meningkatkan akurasi. Untuk mengurangi berat dari Model yang dihasilkan dalam DCNN yang dibuat ini ditambahkan penggunaan Depthwise Convolutional dan menggunakan Global Average Pooling sebagai pengganti Flatten.

D. Definisi Citra Pornografi

Pada penelitian ini sebuah citra dianggap citra pornografi jika menunjukkan secara eksplisit bagian intim. Pada penelitian ini paling banyak yang terlihat eksplisit adalah bagian payudara Wanita. Jika hanya terlihat Sebagian atau tidak secara frontal maka tidak dianggap sebuah citra pornografi.

Pada penelitian ini citra pornografi yang digunakan dalam dataset hanyalah citra dari Wanita saja. Hal ini didasari karena banyaknya penonton yang mencari Wanita saja pada situs Pornografi, yang telah dijelaskan pada bagian pendahuluan. Selain itu citra Wanita yang diambil hanyalah Wanita berkulit putih dan kuning saja yang merupakan mayoritas konten yang dicari dan tersedia.

TABEL I
HASIL TRAINING MODEL DETEKTOR PORNOGRAFI

Model	Akurasi Training	Trainable Parameter	Akurasi Validasi
DCNN 1	86%	135 Juta	-
DCNN 2	74%	41 Juta	-
VGG16	87%	81 Juta	-
ResNet50	94%	23 Juta	53%
Fine Tuned VGG16	97%	28 Juta	70%
Fine Tuned EfficientNetB6	98%	59 Juta	78%
Fine Tuned EfficientNetB3	98%	11.5 Juta	77%

TABEL II
TRAINING TIME MODEL DETEKTOR PORNOGRAFI

MODEL	Training Time/Epoch	Waktu Eksekusi
DCNN 1	12.5 Menit	-
DCNN 2	20 Menit	-
VGG16	7 Menit	-
ResNet50	10 Menit	1 Detik
Fine Tuned VGG16	20 Detik	5.16 Detik
Fine Tuned EfficientNetB6	44 Detik	1.56 Detik
Fine Tuned EfficientNetB3	20 Detik	1.06 Detik

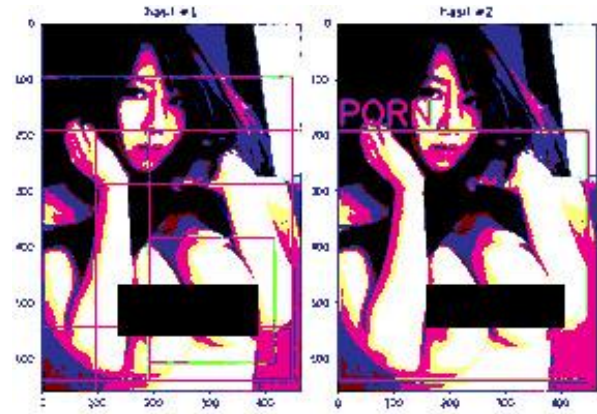
IV. PERCOBAAN DAN ANALISA

A. Dataset


Dataset standar untuk penelitian citra pornografi tidak ada maka dari itu dataset yang akan digunakan untuk percobaan ini dibuat sendiri. Dataset dibuat dari citra yang diambil dari film-film pornografi dari Jepang (Japanese Adult Video) dan film pornografi barat ditambah dengan beberapa citra yang dikumpulkan dari mesin pencarian (seperti Google dan Duckduckgo). Hasil citra yang memiliki kualitas kurang baik, tidak memperlihatkan salah satu organ intim, ataupun yang tidak terlalu jelas menampilkan organ intim difilter secara manual. Citra pada dataset ini berjumlah lebih dari 5500 citra dengan ukuran 224x224 pixel. Pada citra yang ditampilkan dataset memang disensor, tetapi pada dataset yang sebenarnya citra tidak tersensor.

Pada pembuatan dataset beberapa percobaan telah dilakukan agar dapat memperoleh hasil yang baik. Selain citra yang memiliki kualitas kurang baik dan tidak menampilkan salah satu organ intim beberapa seleksi lain juga dilakukan. Hal yang membedakan antara payudara wanita dan dada pada pria adalah ukurannya selain itu terdapat beberapa perbedaan lain seperti Areola dan puting pada payudara wanita yang memiliki ukuran lebih besar, akan tetapi Areola ini sendiri dapat menjadi salah satu penyebab sistem cerdas yang akan dibuat tidak mampu mendeteksinya sebagai fitur pornografi, hal ini dikarenakan warna aerola berwarna mirip sekali dengan warna kulit.

Pada citra yang masuk dalam dataset juga akan difilter berdasarkan ukuran payudaranya, citra yang masuk ke dalam dataset merupakan citra yang memiliki ukuran tubuh proporsional. Selain itu citra yang hanya menampilkan alat kelamin wanita saja juga tidak akan disertakan dalam dataset. Hal ini dikarenakan alat kelamin wanita tidak dengan jelas ditunjukkan dengan citra tersebut, dan seringkali banyak kasus dimana alat kelamin wanita tidak



Gambar. 7. Hasil Deteksi dengan EfficientNetB3



Gambar. 8. Hasil Deteksi dengan EfficientNetB6

memiliki rambut sehingga tidak ada perbedaan dengan citra kulit biasa. Alat kelamin pria juga tidak dijadikan bahan untuk dataset, karena alat kelamin pria jarang ditampilkan secara keseluruhan dan pada citra yang didapat dari film JAV bagian tersebut diberi sensor mosaik. Citra yang tidak masuk ke dalam dataset ini dapat dilihat detailnya pada Gambar 6.

Selain itu dibuat juga dataset lain untuk validasi dengan hasil training. Dataset tersebut adalah dataset validasi yang dibuat dengan cara yang sama dengan dataset untuk training. Dataset ini akan digunakan untuk memvalidasi model yang telah dibuat. Contoh Gambar yang digunakan untuk kedua dataset ini dapat dilihat pada Gambar 5.

B. Hasil Percobaan (Akurasi)

Hasil training dari model yang telah dibuat dapat dilihat pada Tabel 1. Pada tabel ini juga akan ditampilkan jumlah trainable parameter yang dibutuhkan untuk melatih network ini. Pada model yang dihasilkan tidak semua diuji cobakan dengan menggunakan dataset validasi. Model yang memiliki akurasi diatas 90% saja yang diujicobakan.

Pada hasil percobaan dapat dilihat model yang diusulkan gagal untuk memperoleh hasil yang diharapkan. Faktor yang mempengaruhi kegagalannya adalah, kompleksitas dari model kurang walaupun jumlah parameternya sangat banyak. Kompleksitas pada hal ini adalah variasi layer pada model dan kedalaman.

Hasil pada penggunaan transfer learning jauh lebih baik karena model-model yang telah ternama lebih mengembangkan pada kompleksitasnya seperti dapat dilihat hasil dari Resnet yang lebih besar dari pada VGG16, dimana notabene ResNet lebih kompleks dari pada VGG.

Menggunakan Fine Tuning memberikan hasil yang jauh lebih baik lagi, dikarenakan model-model tersebut sebelumnya sudah mampu mendeteksi seperti garis, tepian, dll. Kemudian cukup diberikan sentuhan agar mengenali bagian mana yang merupakan fitur dari citra pornografi. Sedangkan jika ditrain ulang seluruhnya (transfer learning), performa model malah menurun dikarenakan pada proses training ini model belum tentu menemukan fitur-fitur seperti garis dan tepian sebaik sebelumnya.

Fine Tuning menggunakan EfficientNet dicoba dengan menggunakan dua jenis EfficientNet yang berbeda. Percobaan EfficientNet dilakukan dengan menggunakan B6 dan B3. Hasil dari B3 sangatlah baik hanya selisih 1% akurasi dari data validasi. Hasil object detection yang ditunjukkan pada Gambar 7 merupakan hasil dari B3. Hasil dari EfficientNetB6 mampu menampilkan fitur dari berbagai potongan, sedangkan EfficientNetB3 mampu mendeteksi fitur akan tetapi diambil secara garis besarnya saja. Hasil dari EfficientNetB6 dapat dilihat pada Gambar 8.

C. Hasil Percobaan (Training Time)

Training time yang dibutuhkan untuk setiap model juga berbeda-beda, banyaknya parameter serta kompleksitas dari model menentukan durasi yang dibutuhkan untuk mentraining sebuah model. Model yang dibuat dengan menggunakan fine tuned relative memiliki training time yang lebih rendah dikarenakan tidak semua layernya di train. Untuk waktu yang dibutuhkan tiap epochnya dapat dilihat pada Tabel 2.

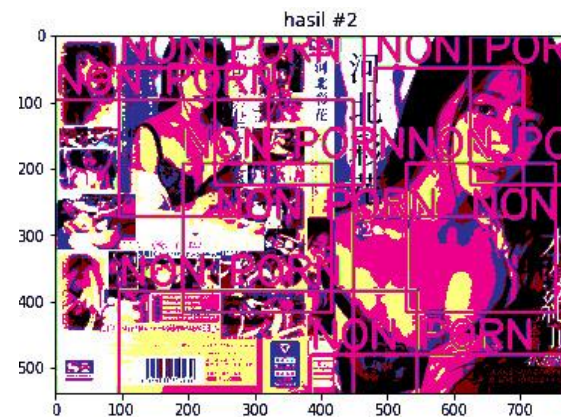

Waktu yang dibutuhkan untuk sebuah model untuk mendeteksi sebuah citra termasuk citra pornografi atau tidaknya dapat tercermin dari training time. Model usulan juga tidak memenuhi kriteria dari sisi kecepatan karena membutuhkan waktu yang sangat lama untuk menjalankan sebuah epochnya. Sebenarnya model dengan Fine Tuned tidak dapat diukur kecepatannya hanya dengan melihat proses trainingnya, akan tetapi model EfficientNetB3 ataupun EfficientNetB6 tetap lebih cepat dalam menjalankan proses training per epochnya dari pada yang diusulkan.

Selain Melakukan percobaan terhadap Training Time/Epoch percobaan waktu eksekusi juga dilakukan. Waktu eksekusi ini diuji coba dengan menggunakan 9 citra pornografi maupun bukan. Citra tersebut terdiri dari beberapa macam jenis yaitu citra binatang, citra pornografi dan citra normal yang tidak menampilkan pornografi. Percobaan akan dilakukan dengan menggunakan bantuan google colab. Pada Google Colab GPU yang digunakan adalah NVIDIA Tesla K80 dan dengan Spesifikasi RAM sebesar 12 GB.

Berdasarkan waktu yang dibutuhkan untuk mendeteksi ke 9 citra tersebut ResNet50 memiliki hasil yang paling cepat dibandingkan Model lainnya. Sedangkan EfficientNet berada pada bawahnya dengan selisih yang tidak jauh berbeda, bahkan untuk EfficientNetB6 yang lebih banyak menggunakan parameter selisih waktu yang dibutuhkan tidaklah banyak. Sedangkan VGG16 yang memiliki jumlah parameter lebih kecil memiliki waktu untuk eksekusi paling lama hingga mencapai 5 detik. Berdasarkan percobaan terhadap waktu dan akurasi pada penelitian ini digunakanlah



Gambar. 9. Hasil Deteksi Lainnya



Gambar. 10. Hasil Deteksi Citra Non Pornografi

Model EfficientNet sebagai model yang digunakan untuk mendeteksi citra pornografi.

D. Object Detection

Model yang terpilih tidak hanya diperiksa keberhasilannya dengan akurasi yang menggunakan dataset validasi saja. Metode lain yang digunakan untuk memeriksa keberhasilan dari model ini dengan mengubah model sehingga dapat diaplikasikan menjadi Detektor Objek. Untuk membuat model hingga menjadi Detektor Objek dibutuhkan beberapa hal yang dilakukan yaitu : Image Pyramid[19], Sliding Windows dan Non Maxima Suppression.

Hasil dari model yang telah diubah menjadi objek Detektor dapat dilihat pada Gambar 6. Pada Gambar 6 area-area yang menjadi fitur dari sebuah citra termasuk citra pornografi dapat dilihat pada kotak hijau. Gambar sebelah

kiri merupakan area-area yang menjadi fitur dari citra yang diinputkan sedangkan pada gambar sebelah kanan memperlihatkan area yang dinilai sebagai pornografi. Pada fitur yang ditemukan akan diseleksi lagi untuk dipilih yang memiliki nilai confidence lebih besar. Kotak hijau/fitur yang memiliki nilai confidence lebih rendah akan dieliminasi gambarannya dapat dilihat pada gambar sebelah kanan. Model ini dianggap berhasil karena mampu mendeteksi area payudara sebagai fitur pornografi.

Gambar 9 menampilkan hasil dari deteksi pada citra pornografi lainnya. Pada citra pornografi ini ada dua buah fitur yang ditampilkan (organ intim dari wanita) yaitu payudara dan alat kelamin wanita. Pada hasil percobaan yang ditampilkan model mampu mendeteksi payudara dan alat kelamin wanita. Hasil tersebut ditunjukkan pada kotak hijau yang ditunjukkan. Akan tetapi untuk deteksi alat kelamin wanita tidak semuanya mampu terdeteksi, untuk alat kelamin wanita yang terdapat rambut kemaluannya saja yang dapat terdeteksi, tanpa itu tidak dapat dibedakan antara kulit biasa atau tidak. Kemampuan untuk mendeteksi alat kelamin wanita ini bukanlah menjadi fokus fitur yang dideteksi pada penelitian ini.

Hasil deteksi untuk citra pornografi dapat dilihat pada Gambar 10. Gambar 10 merupakan citra yang mayoritas merupakan citra non pornografi, ketika dilakukan deteksi tidak ditemukan satupun fitur yang merupakan pornografi. Untuk fitur yang tidak merupakan pornografi ditemukan sangat banyak seperti yang dapat dilihat pada Gambar 8. Akan tetapi sebenarnya pada citra ini terdapat potongan citra pornografi akan tetapi karena dideteksi dengan ukuran 224x224 pixel bagian dari citra pornografi ini tidak terlihat atau bisa dikatakan bagian pornografi pada citra ini dianggap tidak valid untuk dideteksi.

V. KESIMPULAN

Pada penelitian deteksi citra pornografi dilakukan dengan menggunakan Deep Convolutional Neural Network. Untuk setiap citra pornografi yang digunakan telah dipastikan terdapat satu buah fitur pornografi yang tampak secara eksplisit didalamnya (pada penelitian ini adalah payudara wanita). Dengan memastikan hal tersebut memungkinkan pada penelitian ini untuk menggunakan Deep Convolutional Neural Network secara penuh untuk melakukan deteksi pornografi. Bahkan Deep Convolutional Neural Network juga mampu mendeteksi citra pornografi dengan fitur alat kelamin wanita dengan ketentuan tertentu.

Melalui banyak percobaan EfficientNet merupakan model yang paling baik dalam menentukan citra pornografi. Model EfficientNetB6 dianggap paling potensial karena memiliki akurasi yang cukup baik yaitu mencapai 78% dan memiliki waktu untuk mengeksekusi yang cepat (1.56s untuk 9 citra yang berbeda) sedangkan untuk alternatifnya dapat menggunakan model EfficientNetB3 yang memiliki akurasi sedikit lebih rendah dan waktu eksekusi lebih baik. Metode Transfer Learning yang digunakan paling baik menggunakan fine tuning dibandingkan dengan melakukan train ulang untuk seluruh parameter. Hasil yang diperoleh jauh lebih baik dan lebih cepat pada penggunaan Fine Tuning.

Kedepannya penelitian ini akan dikembangkan dan

diterapkan menjadi sebuah sistem cerdas untuk mendeteksi citra pornografi yang tampil pada internet. Penambahan Ekstensi untuk mendeteksi citra pornografi yang tampil pada browser akan dicoba sebagai salah satu metode untuk menerapkan penelitian ini dikemudian hari.

DAFTAR PUSTAKA

- [1] Anonymous, "Enough Is Enough: Pornography." https://enough.org/stats_porn_industry.
- [2] R. Susanto, "Kementerian Komunikasi dan Informatika." https://kominfo.go.id/content/detail/19631/pornografi-masih-merajai-konten-negatif-internet-indonesia/0/sorotan_media.
- [3] Anonymous, "The 2019 Year in Review - Pornhub Insights," 2019. <https://www.pornhub.com/insights/2019-year-in-review>.
- [4] S. Alamgunawan and Y. Kristian, "Klasifikasi Tekstur Serat Kayu pada Citra Mikroskopik Veneer Memanfaatkan Deep Convolutional Neural Network," *J. Intell. Syst. Comput.*, vol. 2, no. 1, pp. 6–11, 2020.
- [5] E. Lim, E. I. Setiawan, and J. Santoso, "Stance Classification Post Kesehatan di Media Sosial Dengan FastText Embedding dan Deep Learning," *J. Intell. Syst. Comput.*, vol. 1, no. 2, pp. 65–73, 2019.
- [6] Kominformo, "TrustPositif." <https://trustpositif.kominformo.go.id/>.
- [7] C. X. Ries and R. Lienhart, "A survey on visual adult image recognition," *Multimed. Tools Appl.*, vol. 69, no. 3, pp. 661–688, 2014.
- [8] M. J. Jones and J. M. Rehg, "Statistical color models with application to skin detection," *Int. J. Comput. Vis.*, vol. 46, no. 1, pp. 81–96, 2002.
- [9] H. A. Nugroho, D. Hardiyanto, and T. B. Adji, "Nipple detection to identify negative content on digital images," in *2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, 2016, pp. 43–48.
- [10] Y. Wang, X. Jin, and X. Tan, "Pornographic image recognition by strongly-supervised deep multiple instance learning," in *2016 IEEE International Conference on Image Processing (ICIP)*, 2016, pp. 4418–4422.
- [11] K. Li, J. Xing, B. Li, and W. Hu, "Bootstrapping deep feature hierarchy for pornographic image recognition," in *2016 IEEE International Conference on Image Processing (ICIP)*, 2016, pp. 4423–4427.
- [12] D. Ganguly, M. H. Mofrad, and A. Kovashka, "Detecting sexually provocative images," in *2017 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 2017, pp. 660–668.
- [13] K. Li, J. Xing, B. Li, and W. Hu, "BOOTSTRAPPING DEEP FEATURE HIERARCHY FOR PORNOGRAPHIC IMAGE RECOGNITION National Laboratory of Pattern Recognition CAS Center for Excellence in Brain Science and Intelligence Technology Institute of Automation, Chinese Academy of Sciences, Beijing 100190, P. R. China."
- [14] S. Dewantono and I. Supriana, "Development of a real-time nudity censorship system on images," in *2014 2nd International Conference on Information and Communication Technology (ICOICT)*, 2014, pp. 30–35.
- [15] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv Prepr. arXiv1409.1556*, 2014.
- [16] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [17] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks." 2019.
- [18] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, 2019.
- [19] T.-Y. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, "Feature pyramid networks for object detection," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 2117–2125.

Disjoint Community Detection pada Network Kegiatan Kemahasiswaan di ISTTS Menggunakan Fast Greedy dan Walktrap

Mikhael Setiawan, *Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya,*
Gunawan, *Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya,*
F.X.Ferdinandus, *Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya.*

Abstrak—Disjoint community detection bertujuan untuk menemukan sebuah komunitas pada network dengan melakukan pemisahan. Pada penelitian ini, disjoint akan dilakukan pada network kegiatan kemahasiswaan di ISTTS. Metode disjoint community detection yang digunakan adalah fast greedy dan walktrap algorithm. Data kegiatan kemahasiswaan berisi mengenai mahasiswa bersama-sama dengan mahasiswa lainnya mengikuti kegiatan kemahasiswaan apa saja. Setelah disjoint berhasil dilakukan, maka akan dihitung nilai closeness centrality dari setiap mahasiswa, dimana pada akhirnya akan dihitung correlation coefficient dengan IPK mahasiswa tersebut untuk mencari hubungan antara centrality mahasiswa dengan IPK mereka. Hasil closeness centrality ini selanjutnya di rata-rata untuk semua hasil algoritma untuk melihat bagaimana korelasi closeness centrality dengan ipk mahasiswa tersebut. Uji coba dilakukan dengan membentuk gml dari kombinasi filter, yang menghasilkan sekitar 2527 gml dengan nilai akhir korelasi adalah 62 - 63% weak positif dengan diikuti 16-18% moderate positif, dan 14-16% tidak berkorelasi sama sekali. Akhirnya dapat disimpulkan bahwa closeness centrality dalam sebuah komunitasnya, hanya berpengaruh secara weak positif dengan ipk mahasiswa tersebut.

Kata Kunci— Closeness Centrality, Correlation Coefficient, Disjoint Community Detection, Network Kegiatan Mahasiswa.

I. PENDAHULUAN

Mahasiswa yang menjalani pendidikan pada sebuah Universitas tidak hanya dituntut untuk berprestasi secara akademis namun juga dituntut memiliki soft skill. Pada universitas ISTTS yang merupakan studi kasus dalam penelitian ini, pengembangan soft skill mahasiswa dibuat dalam bentuk kegiatan dan organisasi kemahasiswaan seperti kegiatan kerohanian, pengembangan minat dan bakat, pengembangan penalaran mahasiswa, dan keorganisasi seperti BEM maupun HIMA.

Ilmu pada social network analysis telah berkembang

sangat pesat, salah satunya pada cabang ilmu community detection. Disjoint community detection adalah salah satu cabang ilmu community detection yang berusaha mencari komunitas-komunitas kecil ini dengan cara dipisahkan. Pada penelitian ini akan digunakan dua jenis disjoint community detection yaitu fast greedy dan walktrap.

Kegiatan bersama yang dilakukan mahasiswa-mahasiswa ini dapat dimodelkan menjadi sebuah network berkegiatan bersama-sama, sebagai contoh bila seorang mahasiswa, anggaplah bernama A sering ditemukan berkegiatan bersama dengan mahasiswa bernama B, maka bisa dianggap kedua mahasiswa ini memiliki hubungan berkegiatan bersama, bahkan lebih jauh kemungkinan besar berteman satu sama lain. Pada penelitian ini, network akan dibangun dari seberapa lama masing-masing mahasiswa berkegiatan bersama dengan mahasiswa lainnya.

Lebih jauh lagi, tidak hanya menemukan komunitas yang lebih kecil, penelitian ini akan berusaha untuk menemukan mahasiswa mana saja yang menjadi central dari komunitas yang lebih spesifik tersebut. Pencarian siapa mahasiswa yang menjadi central dari komunitas tersebut dilakukan dengan melakukan perhitungan nilai closeness centrality, semakin besar nilai closeness ini maka mahasiswa dianggap semakin aktif dan merupakan central dari komunitas.

Hasil nilai closeness centrality mahasiswa dalam komunitas kecil tersebut, nantinya akan coba ditemukan korelasinya dengan indeks prestasi kumulatif atau IPK mahasiswa. Perhitungan korelasi ini akan dilakukan dengan metode pearson correlation coefficient, dengan melihat hubungan antara nilai closeness centrality dengan IPK mahasiswa tersebut.

Beberapa penelitian sejenis yang berusaha untuk menemukan hubungan antara kegiatan kemahasiswaan atau kegiatan ekstrakurikuler diantaranya adalah milik Robert Freeman berjudul the relationship between extracurricular activities and academic achievement[1], dan penelitian milik Gail M. Ritchie dengan judul the impact of academic co-curricular activity participation on academic achievement : a study of catholic high school students[2]. Pada akhirnya penelitian ini bertujuan untuk menjawab beberapa pertanyaan seperti bagaimana hubungan antara kegiatan kemahasiswaan dengan IPK mahasiswa, dan lebih jauh bagaimana hubungan kegiatan kemahasiswaan ini dengan lama study yang ditempuh oleh mahasiswa.

Mikhael Setiawan, Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail : mikhael@stts.edu)

Gunawan, Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail : gunawan@stts.edu)

F.X.Ferdinandus, Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail : ferdi@stts.edu)

II. TINJAUAN PUSTAKA

Pada bagian ini akan dijelaskan beberapa riset yang menjadi landasan teori dari penelitian ini. Fokus utama dari penelitian ini adalah disjoint community detection yang dapat digunakan untuk menemukan komunitas yang lebih kecil dengan melakukan pemisahan[3]. Lebih lanjut, bagian ini akan membahas mengenai algoritma fast greedy dan walktrap sebagai algoritma disjoint community detection, closeness centrality, dan perhitungan korelasi dengan pearson correlation coefficient.

A. Fast Greedy Algorithm

Fast greedy algorithm merupakan pengembangan dari greedy optimization milik Newman. Greedy optimization milik Newman merupakan agglomerative hierarchical clustering, yang termasuk dalam modularity based algorithm dengan tujuan untuk mengoptimalkan nilai modularity Q [4][5]. Nilai modularity Q dapat dihitung dengan menggunakan rumus berikut.

$$Q = \sum_{c=1}^{n_c} \left[\frac{l_c}{m} - \left(\frac{d_c}{2m} \right)^2 \right] \quad (1)$$

Dimana:

- n_c = jumlah cluster
- l_c = total jumlah edges yang menggabungkan vertices dari cluster c
- d_c = sum dari degree pada vertices cluster c
- $\frac{l_c}{m}$ = fraction dari edges pada graph dalam cluster c
- $\left(\frac{d_c}{2m} \right)^2$ = fraction dari edges yang diharapkan pada null model

Nilai modularity ini yang nantinya digunakan untuk menentukan apakah subgraph yang terbentuk dari disjoint community detection merupakan komunitas yang baik atau tidak[6]. Proses yang dilakukan oleh greedy optimization milik Newman dimulai dengan menganggap setiap vertex merupakan anggota tunggal dalam sebuah komunitas. Lalu kedua komunitas ini digabung lalu dihitung nilai modularity Q nya dengan mencari peningkatan nilai modularity Q atau setidaknya bila nilai Q turun, dicari yang penurunannya paling rendah. Proses penggabungan dan penghitungan nilai modularity Q ini dilakukan terus menerus hingga semua vertex menjadi satu buah komunitas, lalu dilakukan proses pemotongan. Pemotongan dilakukan pada iterasi dengan nilai Q paling maksimal.

Beberapa improvement dari segi jenis struktur data, yang ditawarkan pada fast greedy algorithm oleh Clauset adalah menyimpan matrix berisi ΔQ_{ij} untuk pasangan vertex ij , dimana setiap baris dari matrix disimpan sebagai balanced binary tree. Max-heap H digunakan untuk menyimpan element terbesar dari setiap row matrix ΔQ_{ij} beserta dengan label ij sesuai dengan pasangan pada community-nya. Sebuah vector array yang berisi elements a_i , dimana $a_i = \frac{k_i}{2m}$.

Dari jenis struktur data yang ditawarkan itu, maka alur kerja dari fast greedy, dimulai dari menghitung nilai awal ΔQ_{ij} dan a_i , lalu mengisi max-heap H dengan element terbesar dari setiap baris pada matrix ΔQ . Selanjutnya dipilih ΔQ_{ij} terbesar dari max-heap H , lalu gabungkan kedua communities tersebut, lalu update nilai ΔQ , heap H ,

dan a_i , serta naikkan nilai Q akhir dengan ΔQ_{ij} . Langkah ini dilakukan terus hingga muncul 1 komunitas terakhir. Berikut adalah persamaan untuk nilai ΔQ_{ij} dan a_i .

$$\Delta Q_{ij} = \begin{cases} \frac{1}{2m} - \frac{k_i k_j}{(2m)^2} & \text{bila vertex } i, j \text{ terhubung} \\ 0 & \text{bila vertex } i, j \text{ tidak terhubung} \end{cases} \quad (2)$$

$$a_i = k_i / 2m \quad (3)$$

B. Walktrap Algorithm

Algoritma Walktrap yang diperkenalkan oleh Pascal Pons dan Matthieu Latapy ini merupakan pengembangan dari algoritma random walk pada graph, dengan dasar pemikiran bahwa random walks pada graph akan cenderung untuk terjebak pada bagian pada graph yang terkoneksi secara erat (communities). Pascal dkk menggunakan random walks ini untuk menentukan structural similarity antara vertices dan communities, disebut juga sebagai distance[7]. Nantinya, distance ini akan digunakan pada hierarchical clustering algorithm dan membentuk dendrogram pada akhirnya.

Dalam penentuan komunitasnya, walktrap memiliki sebuah nilai inputan yaitu length (t), selain itu walktrap algorithm juga menggunakan jarak r antara vertex nya sebagai perhitungan. Nilai jarak r ini akan semakin besar bila kedua vertices berada di dua community yang berbeda, dan sebaliknya. Dalam penentuan distance r , Pascal dkk merumuskan nilai probabilitas P_{ik}^t .

Menurut Pascal dkk, beberapa catatan yang perlu diingat mengenai probabilitas P_{ij}^t ini adalah jika vertex i dan j berada dalam 1 komunitas maka nilai P_{ij}^t akan tinggi, probabilitas ini dipengaruhi juga oleh degree $d(j)$ karena semakin tinggi nilai degree maka semakin tinggi pula kemungkinan random walker jalan ke vertex tersebut, dan terakhir dua vertex dalam sebuah komunitas memiliki kemungkinan melewati vertex lain dengan cara yang sama sehingga kemungkinan $\forall k, P_{ik}^t \approx P_{jk}^t$. Dari pemahaman tersebut maka dirumuskan nilai distance / jarak r antara vertices adalah sebagai berikut.

$$r_{ij} = \sqrt{\sum_{k=1}^n \frac{(P_{ik}^t - P_{jk}^t)^2}{d(k)}} \quad (4)$$

Setelah distance antara vertices didapatkan, maka dapat digunakan agglomerative hierarchical clustering untuk melakukan disjoint community detection. Walktrap dimulai dengan menganggap semua vertex adalah anggota tunggal 1 buah komunitas, setelah itu lakukan perhitungan jarak r untuk semua vertices yang saling bertetangga. Setelah perhitungan jarak r , lakukan penggabungan dua buah komunitas lalu update semua nilai jarak r setelah penggabungan communities tersebut. Langkah ini dilakukan hingga ditemukan 1 buah komunitas terakhir.

Untuk pemotongan dendrogram komunitas yang terbentuk, Pascal mencetuskan sebuah nilai rasio η_k sebagai alternatif nilai modularity Q yang telah umum dipakai. Namun pada akhirnya nilai modularity Q tetap menjadi pilihan karena selain sudah umum dipakai, Pascal menjelaskan bahwa nilai rasio η_k hampir sama baiknya dengan nilai modularity Q dalam menentukan best cut dari dendrogram yang dihasilkan.

C. Closeness Centrality

Closeness centrality adalah salah satu perhitungan centrality pada social network analysis. Closeness centrality

digunakan untuk menghitung sum jarak dari satu node ke node lainnya[8],[9]. Node/ vertex dengan nilai closeness centrality yang tinggi berarti memiliki jarak paling pendek dengan semua nodes lainnya.

Nilai closeness centrality untuk sebuah node merupakan $1/\text{sum}(\text{jarak node tersebut ke semua node lainnya})$, tidak jarang nilai closeness centrality ini di normalisasi menjadi $(\text{jumlah nodes} - 1)/\text{sum}(\text{jarak node tersebut ke semua node lainnya})$.

$$C(N_i) = 1/[\sum_{j=a}^n d(N_i, N_j)] \quad (i \neq j) \quad (5)$$

$$\text{Norm. } C(N_i) = \frac{n-1}{[\sum_{j=a}^n d(N_i, N_j)]} \quad (i \neq j) \quad (6)$$

Untuk kasus weighted graph, perhitungan closeness centrality tidak mengalami banyak perubahan, kecuali untuk kasus dimana bobot dari edge malah menunjukkan kedekatan/keeratan kedua node tersebut. Pada kasus ini, maka untuk perhitungan closeness centrality nya, semua bobot pada edge harus di-inversed (1/bobot).

D. Pearson Centrality dan Fisher z-transformation

Pearson correlation merupakan perhitungan untuk menentukan apakah 2 variable saling berkorelasi. Beberapa skenario yang dihasilkan dari pearson correlation diantaranya adalah (1) seiring dengan naiknya nilai variable 1, nilai variable 2 juga ikut naik, (2) seiring dengan naiknya nilai variable 1, nilai variable 2 malah turun, (3) kenaikan variable 1 tidak seiring/berlawanan, sehingga sering disebut kondisi tidak ada korelasi[10].

Correlation Coefficient akan mengembalikan nilai antara -1 sampai 1, dimana nilai -1 menandakan strong negatif dan nilai 1 menandakan strong positif. Detail pemetaan intepretasi terhadap nilai correlation coefficient dapat dilihat pada table berikut.

TABEL 1
INTERPRETASI NILAI CORRECAION COEFFICIENT

Nilai Coefficient Correlation	Kekuatan	Positif/Negatif
-1 s/d -0.90	Very strong	Negatif
-0.89 s/d -0.70	Strong	Negatif
-0.69 s/d -0.40	Moderate	Negatif
-0.39 s/d -0.10	Weak	Negatif
-0.09 s/d 0.09	Tidak ada korelasi	
0.10 s/d 0.39	Weak	Positif
0.40 s/d 0.69	Moderate	Positif
0.70 s/d 0.89	Strong	Positif
0.90 s/d 1	Very Strong	Positif

Dari hasil correlation coefficient yang didapat, terkadang ingin diambil nilai rata-rata correlation coefficientnya. Hal ini tidak dapat dilakukan dengan cara rata-rata biasa (mean) karena nilai r akan bias menuju nilai 0, sehingga untuk menyelesaikan masalah bias ini, maka digunakan fisher z-transformation. Pertama-tama, masing-masing nilai r akan diubah menjadi nilai fisher's z :

$$z' = 0.5 \ln \frac{1+r}{1-r} = \text{artanh}(r) \quad (7)$$

Selanjutnya nilai z' ini dapat di rata-rata dan hasil dari rata-rata tersebut akan di ubah kembali menjadi nilai r :

$$r_{z'} = \frac{e^{2z'} - 1}{e^{2z'} + 1} = \tanh(z) \quad (8)$$

Nilai $r_{z'}$, inilah yang akan menjadi nilai rata-rata dari correlation coefficient-nya[11].

E. NetworkX dan IGraph

Pada penelitian ini, akan ada dua tools yang nantinya akan digunakan yaitu NetworkX dan IGraph. NetworkX adalah sebuah package untuk bahasa pemrograman Python yang dapat digunakan untuk melakukan eksplorasi dan analisa terhadap network dan disediakan pula network algoritma [12]. Pada penelitian ini networkx akan digunakan untuk membentuk graph modelling language (gml) dari sumber data kegiatan kemahasiswaan. Beberapa function yang akan digunakan dari NetworkX diantaranya adalah write_gml dan write_pajak.

Igraph adalah koleksi dari network analysis tools yang mengutamakan efisiensi, portability, kemudahan dalam penggunaannya, dan tersedia untuk bahasa pemrograman R, Python, Mathematica, dan C/C++[13]. Pada penelitian ini, penggunaan igraph dilakukan karena NetworkX sampai pada saat tulisan ini ditulis, tidak memiliki function bantuan untuk algoritma fast greedy dan walktrap, sedangkan igraph memiliki function ini. Beberapa function yang akan digunakan dari igraph diantaranya adalah community_fastgreedy dan community_walktrap dengan parameter yang dapat ditentukan.

F. Vis.js dan Pajak

Pada penelitian ini, digunakan vis.js dan pajak sebagai alat bantu visualisasi pada website. Pajak dipilih sebagai alat bantu visualisasi komunitas yang terbentuk karena performanya yang baik [14]. Untuk pajak, penelitian ini akan menyediakan hasil network dalam bentuk file .net dan hasil disjoint community detection dalam bentuk file .clu

Vis.js adalah salah satu library javascript untuk memvisualisasikan network beserta dengan hasil komunitas yang terbentuk dengan bantuan warna, sehingga dapat ditampilkan langsung pada website [15].

G. Relevant Literature milik Robert Freeman

Salah satu penelitian yang menjadi rujukan adalah penelitian milik Robert Freeman[1]. Pada penelitian ini, independent variable adalah partisipasi siswa pada kegiatan ekstrakurikuler. Dependant variable adalah skor ACT dan prestasi akademik (GPA). Frequency distribution digunakan untuk memvisualisasikan relasi ACT, GPA, dan kegiatan ekstrakurikuler. Metode yang digunakan adalah coefficient correlation antara variable yang telah disebutkan sebelumnya.

Beberapa research question yang ditanyakan pada penelitian Robert diantaranya adalah seberapa signifikan pengaruh dari jumlah dan partisipasi seorang siswa dalam ekstrakurikuler dengan ACT dan GPA yang didapat. Beberapa variable lain yang diperhitungkan adalah pengaruh jenis kelamin, free, reduced lunch status, dan jumlah ekstrakurikuler dengan GPA, namun penelitian ini tidak memperhitungkan variable-variable ini.

Hasil yang didapatkan adalah ketika siswa mengikuti kegiatan ekstrakurikuler, terjadi peningkatan pada GPA yang didapatkan, tidak peduli jenis kelamin dari siswa tersebut. Skor coefficient correlation yang didapatkan adalah 0.33 yang mengindikasi bahwa ada pengaruh weak positif antara GPA dan kegiatan ekstrakurikuler.

H. Relevant Literature milik Gail M. Ritchie

Salah satu penelitian yang menjadi rujukan adalah penelitian milik Gail M. Ritchie[2]. Pada penelitian ini, variable yang diperhitungkan adalah academic co-curricular activity participation (ACCAP) dan GPA. Penelitian ini memiliki research question yang hamper sama dengan milik Robert, yaitu seberapa jauh keterlibatan siswa dalam kegiatan extracurricular dengan academic performance yang didapatkan. Penelitian ini juga melibatkan intensitas keterlibatan dalam ekstrakurikuler, gender, dan etnis, namun kembali lagi, gender dan etnis tidak menjadi variable dalam penelitian ini. Metode penelitian yang dilakukan adalah mencari coefficients dari regression models.

Hasil yang didapatkan adalah semakin lama dan semakin sering seorang siswa mengikuti academic co-curricular activities, maka terjadi peningkatan GPA sebanyak 0.13 point. Gail M. Ritchie juga menjelaskan bahwa pada penelitian sebelumnya yang dilakukan Reeves juga menyatakan bahwa semakin meningkatnya ACCAP, maka performa akademik juga meningkat.

III. METODE DAN ALUR PENELITIAN

Pada bagian ini akan dijelaskan metode penelitian yang digunakan dalam perhitungan korelasi antara closeness centrality mahasiswa hasil dari disjoint community detection. Penjelasan akan meliputi sumber data, representasi network, alur sistem, dan visualisasi hasil.

A. Sumber Data

Sumber data berasal dari kegiatan kemahasiswaan yang terjadi di ISTTS. Data dibagi menjadi 2 bagian yaitu data kegiatan kemahasiswaan dan data organisasi kemahasiswaan. Kegiatan maupun organisasi ini dibagi-bagi menjadi empat kategori yaitu minat bakat, penalaran, organisasi dan kerohanian.

Data kegiatan berkisar 1282 data, yang berisi detail kegiatan seperti kode, nama, tanggal kegiatan dimulai dan berakhir, kategori kegiatan dan organisasi penyelenggara. Data struktur kegiatan yang berisi mahasiswa siapa saja yang mengikuti kegiatan tersebut, berkisar 42.429 data.

Data organisasi berkisar 673 data, yang berisi detail organisasi seperti kode, kategori, nama, tanggal mulai dan berakhirnya organisasi. Organisasi seperti BEM atau HIMA memiliki durasi kerja sekitar satu tahun, sedangkan organisasi seperti unit kegiatan kerohanian (UKK) dan unit kegiatan mahasiswa (UKM) memiliki durasi kerja sekitar satu semester. Data struktur organisasi yang berisi mahasiswa siapa saja yang mengikuti organisasi tersebut, berkisar 15.708 data.

Beberapa data dari sumber data tidak lengkap, misalnya seperti tanggal berakhirnya kegiatan atau keorganisasian tidak ada, sehingga dilakukan beberapa pembenaran data seperti memberikan nilai default satu semester atau satu tahun untuk organisasi-organisasi seperti BEM, HIMA, UKM, ataupun UKK.

B. Representasi Network

Berdasarkan sumber data yang ada, selanjutnya dilakukan proses untuk mengubah data menjadi network, dalam format graph modelling language (gml). Pada penelitian ini, data mahasiswa merepresentasikan node / vertex, sedangkan

untuk edge yang terbentuk dari antara node dilihat dari apakah kedua orang mahasiswa pernah berkegiatan bersama dalam sebuah kegiatan atau tidak.

Hasil dari step ini adalah sebuah gml dari weighted undirected network. Untuk pembentukan gml-nya, digunakan bantuan library NetworkX. Sebagai contoh, bila mahasiswa A dan mahasiswa B pernah berkegiatan bersama dalam kegiatan X dan organisasi Y, maka akan dibuatkan dua buah node yaitu A dan B, lalu kedua node tersebut akan dihubungkan dengan sebuah edge. Berdasarkan contoh, durasi lama kegiatan dan organisasi tersebut berlangsung, dalam satuan hari, akan dijumlah dan dijadikan nilai bobot/weight dari edge penghubung node A dan B. Semakin lama durasi kegiatan dan semakin sering kedua mahasiswa terlibat kegiatan bersama, maka semakin besar nilai weight dari edge. Mengingat nilai bobot ini digunakan untuk ukuran kekuatan hubungan antara node, maka nanti pada saat perhitungan closeness centrality, bobot ini akan di inverted.

```
graph [
  node [
    id 0
    label "217140071"
    mhs_nama "ERIC SAN FOKALIE"
    jur_kode "14"
    jur_nama "S1-DESAIN PRODUK"
    mhs_ipk 3.32
    mhs_poin 1270
    angkatan "2017"
  ]
  node [
    id 1
    label "217140072"
    mhs_nama "GERARD RUSTADY"
    jur_kode "14"
    jur_nama "S1-DESAIN PRODUK"
    mhs_ipk 3.47
    mhs_poin 2957
    angkatan "2017"
  ]
  edge [
    source 0
    target 1
    weight 3
  ]
]
```

Gambar. 1. Contoh gml yang dihasilkan dengan memuat node dan edge

Pada Gambar. 1, dapat dilihat gml akan menyimpan data mahasiswa seperti nama, jurusan, angkatan, dan ipk mahasiswa tersebut dalam daftar node, sedangkan pada daftar edgenya akan berisi node mana saja yang saling berhubungan dengan diberikan informasi weight.

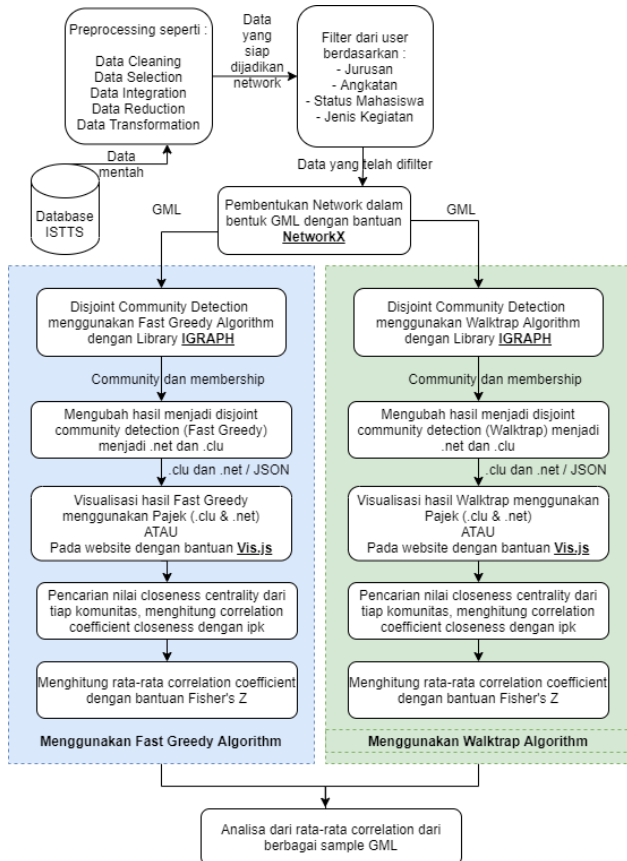
C. Alur Penelitian

Alur penelitian dalam penelitian ini dapat dilihat pada Gambar. 2. Alur akan dijelaskan mulai dari data mentah, preprocessing, pembentukan gml, disjoint community detection, pencarian nilai closeness, pencarian nilai rata-rata closeness, hingga pembuktian hipotesa yaitu ada tidaknya korelasi antara semakin berpengaruhnya seorang mahasiswa dalam komunitas dengan IPK yang dimilikinya.

Alur penelitian ini sedikit berbeda dengan penelitian yang dilakukan oleh Robert dan Gail M. Ritchie. Penelitian Robert hanya melakukan perhitungan correlation, dan penelitian Gail M. Ritchie melakukan regression model. Kedua penelitian rujukan tidak melakukan proses disjoint

community detection, dan hanya melakukan perhitungan korelasi saja.

Pada Gambar. 2, dapat dilihat alur dimulai dengan mendapatkan data dari sumber data yaitu kegiatan kemahasiswaan ISTTS, dilanjutkan dengan preprocessing seperti membersihkan data yang terlalu tua dan tidak valid misalnya data kegiatan tahun 1990-an. Setelah data sudah cukup baik dan dapat digunakan, preprocessing dilanjutkan dengan mengambil hanya kolom-kolom yang perlu saja seperti kategori, tanggal awal, tanggal selesai kegiatan/ organisasi, dan data mahasiswa seperti nrp, nama, jurusan, dan angkatan.



Gambar. 2. Block Diagram Alur Kerja Penelitian

Setelah data siap, lalu dilakukan pembentukan network GML seperti yang telah dijelaskan pada subbab sebelumnya. Pembentukan gml ini akan dipengaruhi oleh filter yang dimasukkan oleh pengguna. Filter pencarian yang disediakan adalah jurusan, angkatan, status mahasiswa, dan jenis kegiatan. Jurusan adalah jurusan mahasiswa tersebut seperti informatika, industri, dan sebagainya. Angkatan adalah angkatan mahasiswa masuk. Status mahasiswa disini adalah aktif tidak nya mahasiswa tersebut, dimana nilai 0 menandakan mahasiswa tersebut tidak aktif/ dropout, nilai 1 menandakan mahasiswa tersebut aktif, nilai 9 menandakan mahasiswa tersebut telah lulus/ menjadi alumni. Jenis kegiatan/ organisasi dibagi menjadi 4 kategori yaitu minat bakat, organisasi, penalaran, dan kerohanian.

GML yang terbentuk selanjutnya akan melalui proses disjoint community detection, seperti yang dapat dilihat pada Gambar. 2, untuk disjoint dapat dipilih ingin menggunakan fast greedy atau walktrap. Dari hasil disjoint

community detection baik menggunakan fast greedy maupun walktrap, akan didapat komunitas yang dianggap baik. Dari setiap komunitas tersebut akan dibentuk sebuah subgraph lalu dihitung nilai closeness centrality-nya untuk masing-masing node mahasiswa.

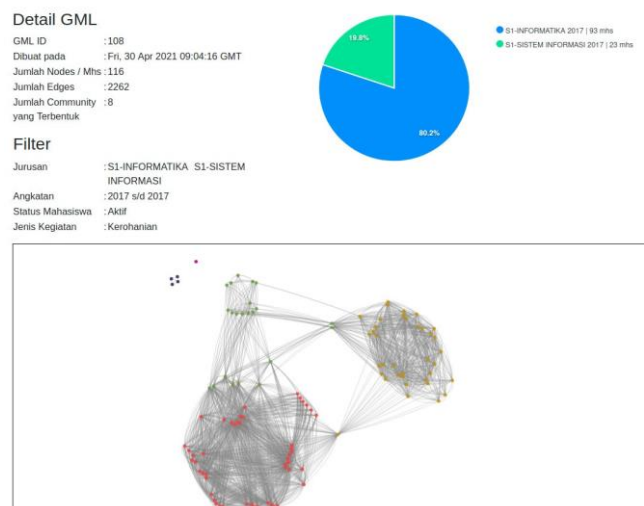
Nilai closeness centrality ini akan menunjukkan mahasiswa mana yang dianggap dapat menyalurkan informasi dengan lebih cepat ke semua mahasiswa lain, atau paling berpengaruh dan memegang informasi penting[16],[17]. Semakin berpengaruh seorang mahasiswa, biasanya semakin aktif mahasiswa tersebut dalam berkegiatan dan bersosialisasi dengan mahasiswa lainnya, dan memiliki jabatan yang tinggi seperti ketua.

Nilai closeness ini selanjutnya dihitung korelasinya dengan IPK mahasiswa tersebut dengan menggunakan pearson correlation coefficient. Karena komunitas kecil yang dihasilkan biasanya lebih dari satu dari sebuah GML, maka nilai correlation coefficient ini selanjutnya di rata-rata dengan mentransformasikan terlebih dahulu menggunakan Fisher's z-transformation. Hasil rata-rata nilai korelasi inilah yang nantinya akan diolah lebih jauh dengan melihat rata-rata nilai korelasi dari GML lain, tentu saja dengan filter dan studi kasus yang berbeda-beda.

D. Visualisasi Hasil Disjoint

Pada penelitian ini, juga dilakukan visualisasi dari hasil disjoint yang dilakukan, meskipun visualisasi merupakan hal vital dalam pembuktian hipotesa penelitian. Visualisasi akan berisi detail gml yang dihasilkan seperti jumlah nodes, jumlah edges, jumlah komunitas yang terbentuk, nilai modularity yang didapatkan, filter-filter yang berpengaruh dalam pembentukan gml, lalu akan ada visualisasi hasil akhir network beserta komunitas-komunitas yang telah ditandai dengan warna yang berbeda-beda untuk setiap nodes yang merupakan anggotanya. Berikut adalah contoh hasil visualisasi dengan menggunakan vis.js.

Visualisasi GML



Gambar. 3. Contoh visualisasi dari hasil GML dan disjoint community detection

Pada subbab-subbab berikutnya, visualisasi tidak hanya menggambarkan hasil dari disjoint community detection, tapi juga akan memvisualisasikan hasil analisa dari closeness centrality, dan average correlation coefficient.

TABEL 2
REKAP HASIL SKENARIO FILTER PER ANGKATAN UNTUK JURUSAN ELEKTRO, INFORMATIKA, INDUSTRI, DESPRO, DKV, DAN SIB

Filter	Filter Kategori Kegiatan	Kategori Organisasi	POSITIF				NEGATIF				
			Very Strong	Strong	Moderate	Weak	No Corr	Weak	Moderate	Strong	Very Strong
2015	MIN,NAL,ORG,ROH	MIN,ORG,ROH	0.63	6.35	62.86	29.84	0.32	0	0	0	0
2015	MIN,ORG,ROH	MIN,ORG,ROH	0	9.52	37.46	40.95	11.11	0.95	0	0	0
2015	MIN,ROH	MIN,ROH	0	0	6.84	64.17	20.52	7.49	0.98	0	0
2015	ROH	ROH	0	1.61	14.84	74.84	7.1	0.32	1.29	0	0
2016	MIN,NAL,ORG,ROH	MIN,ORG,ROH	0	0	23.49	69.84	0.95	2.54	1.9	1.27	0
2016	MIN,ORG,ROH	MIN,ORG,ROH	0	0	16.51	77.78	0.63	2.22	1.59	1.27	0
2016	MIN,ROH	MIN,ROH	0	1.61	10.93	70.74	12.86	3.86	0	0	0
2016	ROH	ROH	0.33	1.63	22.8	68.08	6.84	0.33	0	0	0
2017	MIN,NAL,ORG,ROH	MIN,ORG,ROH	0	0	6.67	65.4	24.76	1.59	0	1.59	0
2017	MIN,ORG,ROH	MIN,ORG,ROH	0	0	6.51	65.8	24.43	1.63	0	1.63	0
2017	MIN,ROH	MIN,ROH	0	0.32	26.35	40.63	25.4	5.71	1.59	0	0
2017	ROH	ROH	0	0	11.75	46.67	34.29	5.71	1.59	0	0
2018	MIN,NAL,ORG,ROH	MIN,ORG,ROH	0	0	30.79	61.9	0.63	5.08	1.59	0	0
2018	MIN,ORG,ROH	MIN,ORG,ROH	0	0	27.62	70.79	0	0	1.59	0	0
2018	MIN,ROH	MIN,ROH	0	0.64	37.62	41.16	10.29	9.97	0.32	0	0
2018	ROH	ROH	1.63	1.63	1.63	2.94	53.59	35.29	0	3.27	0

* Semua angka korelasi dalam bentuk persentase (%)

** Min : minat bakat, Nal : penalaran, Roh : kerohanian, Org : organisasi


IV. HASIL EKSPERIMEN DAN UJI COBA

Pada bagian ini akan dijelaskan mengenai hasil ujicoba yang dilakukan pada berbagai macam filter dan gml. Pada semua uji coba, metode yang akan dipakai adalah fastgreedy, walktrap dengan nilai $t=2,4,6$, dan 8 .

Beberapa skenario yang akan dibahas adalah filter per angkatan, filter per jurusan, multi-angkatan multi-jurusan, rekap top-3 mahasiswa dilihat dari IPK, rekap top-3 mahasiswa dilihat dari lama studi, dan analisa efektifitas dan performa dari kedua algoritma, serta pembahasan hasil penelitian dibandingkan dengan milik Robert dan Gail M. Ritchie

A. Skenario Filter Per Angkatan

Pada skenario ujicoba ini, gml yang terbentuk pasti hanya satu angkatan saja, misalnya hanya mahasiswa yang memiliki angkatan 2017 saja. Jurusan yang terlibat adalah elektro, informatika, industri, despro, dkv, dan sib. Jurusan lain tidak dimasukkan ke dalam uji coba dikarenakan jumlah mahasiswa yang tidak terlalu banyak. Bahkan pada beberapa jurusan seperti S2 informasi tidak menuntut mahasiswa untuk mengikuti kegiatan kemahasiswaan.




Gambar. 4. Avg. Correlation Coefficient pada angkatan 2017 kategori ROH

Pada Gambar. 4, merupakan salah satu contoh grafik average correlation, dengan filter angkatan 2017, jurusan elektro, informatika, industri, despro, dkv, dan sib. Pada

Tabel 2, dapat dilihat rekap hasil skenario beberapa sample ujicoba, untuk angkatan 2015 – 2018, dengan beberapa kombinasi kategori kegiatan, dimana dari hasil dapat disimpulkan bahwa, korelasi keseluruhan adalah : 0.16% very strong positif, 1,46% strong positif, 21.63% moderate positif, 55.75% weak positif, 14.54% tidak ada korelasi, 5.13% weak negatif, 0.78 moderate negatif, 0.56 strong negatif, dan 0% very strong negatif.

B. Skenario Filter Per Jurusan

Pada skenario uji coba ini, gml yang terbentuk pasti hanya dari satu jurusan saja, misalnya informatika. Angkatan yang akan dilibatkan adalah angkatan 2015 sampai 2018. Untuk skenario ini jurusan yang akan di uji coba hanya sib dan informatika, karena jurusan lain seperti elektro memiliki data mahasiswa yang terlalu kecil.



Gambar. 5. Avg. Correlation Coefficient pada jurusan SIB kategori ROH

Pada Gambar. 5, dapat dilihat kombinasi yang muncul menjadi lebih sedikit dibandingkan Gambar. 4. Pada Tabel 3, dapat dilihat bahwa yang diuji coba hanya jurusan informatika dengan kode jurusan 11 dan sib dengan kode jurusan 18 saja. Dari hasil percobaan ini didapatkan bahwa rekap korelasi : 0% very strong positif, 0% strong positif, 27.5% moderate positif, 42.5% weak positif, 23.5% tidak ada korelasi, 6.25% weak negatif, 0.25% moderate negatif, 0% strong negatif, dan 0% very strong negatif.


TABEL 3
REKAP HASIL SKENARIO FILTER PER JURUSAN UNTUK ANGGATAN 2015 HINGGA 2018

Filter	Filter	Kategori Kegiatan	Kategori Organisasi	POSITIF				NEGATIF			
				Very Strong	Strong	Moderate	Weak	No Corr	Weak	Moderate	Strong
11	MIN,NAL,ORG,ROH	MIN,ORG,ROH	MIN,ORG,ROH	0	0	74	26	0	0	0	0
11	MIN,ORG,ROH	MIN,ORG,ROH	MIN,ORG,ROH	0	0	68	32	0	0	0	0
11	MIN,ROH	MIN,ROH	MIN,ROH	0	0	28	50	18	4	0	0
11	ROH	ROH	ROH	0	0	0	20	76	4	0	0
18	MIN,NAL,ORG,ROH	MIN,ORG,ROH	MIN,ORG,ROH	0	0	10	80	10	0	0	0
18	MIN,ORG,ROH	MIN,ORG,ROH	MIN,ORG,ROH	0	0	18	54	12	16	0	0
18	MIN,ROH	MIN,ROH	MIN,ROH	0	0	12	46	22	18	2	0
18	ROH	ROH	ROH	0	0	10	32	50	8	0	0

C. Skenario Multi-Angkatan dan Multi-Jurusan

Pada skenario ujicoba ini, akan menggabungkan 6 jurusan sekaligus yaitu elektro, informatika, industri, despro, dkv, dan sib dengan 4 angkatan sekaligus yaitu 2015-2018.

Pada Gambar. 6, grafik yang dihasilkan mejadi lebih rapat karena banyaknya kombinasi, namun masih bisa dilihat bahwa hasil average correlation masih berkisar antara weak positif, dan tidak ada korelasi, dengan beberapa lonjakan average correlation ke moderate positif.



Gambar. 6. Avg. Correlation Coefficient pada kombinasi 3 jurusan (dkv,inf,sib) dengan 3 angkatan (2015-2017) pada kategori ROH

Pada Tabel 4, untuk kolom kategori kegiatan/ organisasi tidak ditampilkan karena data setiap baris sudah memuat kombinasi (1) Roh, (2) Min, Roh, (3) Min, Org, Roh, (4) Min, Org, Roh, Nal. Pada tabel ini, jumlah jurusan dan jumlah angkatan menunjukkan berapa banyak kombinasi yang dimuat dalam satu baris, sebagai contoh baris pertama

TABEL 4
REKAP HASIL SKENARIO UNTUK MULTIPLE JURUSAN DAN ANGGATAN

Filter	Jumlah Jurusan	Jumlah Angkatan	Very Strong	POSITIF				NEGATIF			
				Strong	Moderate	Weak	No Corr	Weak	Moderate	Strong	Very Strong
	2	2	0	0.11	24.56	52	19.22	3.67	0.44	0	0
	2	3	0	0	15.17	65.17	17.17	2.17	0.33	0	0
	2	4	0	0	17.67	64.67	16.33	1.33	0	0	0
	3	2	0	0	16.08	66	14.67	2.25	1	0	0
	3	3	0	0	6.5	77.5	14.5	1.5	0	0	0
	3	4	0	0	7.5	77	14.5	1	0	0	0
	4	2	0	0	9.67	74.67	14.44	0.44	0.78	0	0
	4	3	0	0	2.5	82.17	15.33	0	0	0	0
	4	4	0	0	1.67	84.33	14	0	0	0	0
	5	2	0	0	5.83	81.67	12.22	0	0.28	0	0
	5	3	0	0	2.08	83.33	14.58	0	0	0	0
	5	4	0	0	0	87.5	12.5	0	0	0	0
	6	2	0	0	0	90	10	0	0	0	0
	6	3	0	0	0	87.5	12.5	0	0	0	0
	6	4	0	0	0	90	10	0	0	0	0

dengan 2 jurusan dan 2 angkatan berarti sudah memuat kombinasi inf,sib (2015-2016), dkv,despro (2016-2017), dan seterusnya hingga semua kombinasi 2 jurusan dan 2 angkatan termasuk didalam perhitungan baris pertama.

Pada akhirnya dari skenario uji coba ini didapatkan rekap korelasi : 0% very positif, 0.01% strong positif, 11.3% moderate positif, 71.59% weak positif, 15.29% tidak ada korelasi, 1.42% weak negatif, 0.38% moderate negatif, 0% strong negatif, dan 0% very strong negatif.

D. Skenario Rekap Keseluruhan

Setelah berbagai kombinasi percobaan yang telah diujicobakan didapatkan hasil akhir dari nilai average correlation yang terbentuk antara closeness centrality dengan IPK mahasiswa untuk setiap metode yang dilakukan.

TABEL 5
REKAP HASIL KESELURUHAN BERDASARKAN METODE

Metode	Moderate Positif	Weak Positif	Tidak ada korelasi
FG	18.0	62.4	15.9
WT2	15.2	63.6	15.1
WT4	15.2	64.0	14.8
WT6	16.3	62.9	15.2
WT8	16.6	62.9	14.7

*Pada table ini, tidak ditampilkan korelasi lain seperti weak negatif, moderate negatif, dan seterusnya karena persentase yang sangat kecil (mendekati 0)

Pada Tabel 5, rekap average correlation dilihat dari setiap metode yang digunakan dalam uji coba yaitu fast greedy (FG) dan walktrap (WT) dengan nilai t=2,4,6,8. Pada ujicoba keseluruhan ini, terdapat sekitar 2527 kombinasi filter yang mencampur jurusan, angkatan, dan kategori kegiatan/organisasi. Dari hasil yang ditampilkan, terlihat bahwa hampir semua metode mengeluarkan hasil weak

positif untuk korelasi antara closeness centrality mahasiswa dengan ipknya, diikuti dengan moderate positif dan tidak ada korelasi.

E. Rekap Top-3 Dilihat dari IPK

Pada subbab ini akan dijelaskan bagaimana informasi hasil yang sudah didapatkan sebelumnya, diolah lebih jauh untuk kontribusi yang lebih jauh. Dengan mengambil data mahasiswa yang paling sering muncul sebagai top, dalam hal ini kita sebut saja sebagai top-3 mahasiswa dengan nilai closeness centrality tertinggi dalam sebuah komunitas hasil disjoint community detection, maka bisa didapatkan beberapa informasi seperti mahasiswa mana saja yang dianggap sebagai mahasiswa yang paling “penting” dalam berbagai komunitas yang ada, bagaimana performa mahasiswa-mahasiswa top ini dalam bidang akademik seperti IPK.

Kedua algoritma menghasilkan sekitar 15 ribu sampai 20 ribu kemunculan data mahasiswa yang dianggap sebagai top-3 closeness centrality dari semua GML yang dihasilkan. Dari hasil rekap, dapat dilihat bahwa rata-rata 30-32% mahasiswa memiliki IPK 3-3.5 dengan predikat sangat memuaskan, 22-24% mahasiswa memiliki IPK 3.7-3.9 dengan predikat magna cumlaude, 19-21% mahasiswa memiliki IPK 2.5-3 dengan predikat memuaskan, 15-16% mahasiswa memiliki IPK 3.5-3.7 dengan predikat cumlaude, dan sisanya, seperti IPK kurang dari 2.5 atau IPK diatas 3.7

Dari hasil tersebut, maka pada studi kasus di ISTTS, tidak benar bila ada anggapan bahwa mahasiswa yang aktif berkegiatan, maka akan memiliki nilai IPK yang jelek, sebaliknya justru sebagian besar mahasiswa ini memiliki IPK yang bisa dibilang cukup baik.

F. Rekap Top-3 Dilihat dari Masa Studi

Pada subbab ini, akan dibahas mengenai rekap top-3 mahasiswa dilihat dari masa studi yang telah ditempuh oleh mahasiswa. Untuk jumlah data mahasiswa top-3 masih sama dengan rekap top-3 mahasiswa dilihat dari IPK yang dicapai, seperti yang dijelaskan pada subbab sebelumnya.

Hasil yang didapatkan adalah 45%-46% mahasiswa belum lulus, 34%-36% mahasiswa lulus tepat waktu, 16-17% mahasiswa lulus, namun kelebihan satu tahun dari waktu seharusnya, sisanya, adalah mahasiswa yang lulus tapi lebih dari 2 tahun dari waktu seharusnya.

Dari hasil ini dapat disimpulkan bahwa, pada studi kasus ISTTS, tidak benar kalau ada pernyataan yang mengatakan bahwa mahasiswa yang aktif berkegiatan, tidak lulus-lulus / lulusnya terlambat. Dari dua buah contoh rekap top-3 mahasiswa dari lama studi dan IPK, dapat dilihat bahwa penelitian dalam bidang disjoint community detection ini, bisa menghasilkan banyak sekali deskriptif model untuk menghasilkan sejumlah informasi baru yang sebelumnya belum diketahui.

G. Analisa Performa dan Hasil

Pada subbab ini akan sedikit dijelaskan mengenai analisa performa dari fastgreedy dan walktrap. Pada penelitian ini, tidak akan dijelaskan mengenai bagaimana performa kecepatan dan nilai modularity yang dihasilkan dari kedua algoritma ini, dalam menghandle network dalam ukuran besar, karena hal ini telah disampaikan oleh Pascal et al pada papernya[7].

Pada penelitiannya, Pascal menunjukkan perbandingan fast greedy dengan walktrap dengan nilai $t=2$ dan $t=5$, dimana kedua algoritma ini menghasilkan nilai modularity / time dalam detik yang hampir sama pada network kecil seperti karate club, dan nilai modularity yang lebih kecil dari fast greedy pada network www, namun dengan peningkatan time waktu pada walktrap $t=2$ dibandingkan dengan fast greedy.

Pada penelitian ini, dilihat dari subbab-subbab sebelumnya dapat dilihat bahwa sekitar 60% menyatakan ada relasi weak positif antara kegiatan kemahasiswaan dengan IPK yang diraih oleh mahasiswa. Hasil ini sejalan dengan dua paper rujukan yaitu milik Robert dan milik Gail M. Ritchie, sehingga dapat ditarik kesimpulan untuk menjawab research question pada penelitian ini, yaitu ada pengaruh meskipun secara weak antara keaktifan mahasiswa dengan IPK yang diraih. Selain itu, didapatkan bahwa semakin aktif mahasiswa tersebut, bahkan bila mahasiswa tersebut menjadi mahasiswa penting atau top-3, maka IPK yang diraih juga cukup baik dan lama studi mereka sebagian besar adalah lulus tepat waktu.

V. KESIMPULAN

Dari hasil penelitian yang telah dilakukan, dapat diambil beberapa kesimpulan. Hubungan antara nilai closeness centrality seorang mahasiswa ISTTS yang menandakan mahasiswa tersebut adalah pusat dari sebuah komunitas, dengan ipk, didapatkan mahasiswa tersebut cenderung weak positif, hal ini dapat dilihat dari perhitungan korelasi secara keseluruhan menyatakan 62 - 63% weak positif dengan diikuti 16-18% moderate positif, dan 14-16% tidak berkorelasi sama sekali.

Hasil komunitas yang dibentuk oleh ketiga jenis metode ini pun hampir sama dalam pembentukan komunitasnya, terlihat dari hasil average closenessnya yang tidak terlalu sering berbeda terlalu jauh, terutama untuk walktrap dengan nilai $t=6$ dan 8.

Data kemahasiswaan, terutama mahasiswa ISTTS tergolong cukup kecil dimana terdapat trend banyak sekali mahasiswa yang terlibat dalam suatu kegiatan terus menerus atau malah tidak terlibat kegiatan apapun sama sekali, ini terbukti dari bentuk graph/gml yang dihasilkan selalu berbentuk dense graph, sekaligus disconnected graph terhadap beberapa mahasiswa yang enggan ikut kegiatan apapun.

Beberapa masalah yang muncul dalam penelitian ini adalah algoritma walktrap terutama yang didevelop oleh igrph sering menghasilkan incomplete dendogram, sehingga tidak bisa didapatkan hasil komunitasnya/ cluster. Selain itu komunitas yang terbentuk pun sering berupa disconnected graph yang mempersulit perhitungan closeness centrality.

Beberapa saran untuk penelitian selanjutnya adalah menggunakan function `fix_dendogram` untuk membenarkan dendogram milik walktrap, dan mengganti closeness centrality dengan harmonic centrality. Penelitian juga dapat dikembangkan untuk menjadi deskriptif modelling untuk mendapatkan informasi baru yang sebelumnya belum diketahui, seperti contohnya pada penelitian ini dilakukan analisa lebih jauh mengenai rekap top-3 mahasiswa dan

pengaruhnya pada IPK dan lama studi.

DAFTAR PUSTAKA

- [1] R. Freeman, "The relationship between extracurricular activities and academic achievement," 2017.
- [2] G. M. Ritchie, "The Impact of Academic Co-Curricular Activity Participation on Academic Achievement: A Study of Catholic High School Students," 2018.
- [3] S. Fortunato, "Community detection in graphs," *Phys. Rep.*, vol. 486, no. 3–5, pp. 75–174, 2010.
- [4] M. E. J. Newman, "Fast algorithm for detecting community structure in networks," *Phys. Rev. E*, vol. 69, no. 6, p. 66133, 2004.
- [5] M. E. J. Newman, "Detecting community structure in networks," *Eur. Phys. J. B*, vol. 38, no. 2, pp. 321–330, 2004.
- [6] S. Paul and Y. Chen, "Null models and modularity based community detection in multi-layer networks," *arXiv Prepr. arXiv1608.00623*, 2016.
- [7] P. Pons and M. Latapy, "Computing communities in large networks using random walks," in *International symposium on computer and information sciences*, 2005, pp. 284–293.
- [8] J. Zhang and Y. Luo, "Degree centrality, betweenness centrality, and closeness centrality in social network," in *Proceedings of the 2017 2nd International Conference on Modelling, Simulation and Applied Mathematics (MSAM2017)*, 2017, vol. 132, pp. 300–303.
- [9] T. Opsahl, F. Agneessens, and J. Skvoretz, "Node centrality in weighted networks: Generalizing degree and shortest paths," *Soc. Networks*, vol. 32, no. 3, pp. 245–251, 2010.
- [10] P. Schober, C. Boer, and L. A. Schwarte, "Correlation coefficients: appropriate use and interpretation," *Anesth. & Analg.*, vol. 126, no. 5, pp. 1763–1768, 2018.
- [11] D. M. Corey, W. P. Dunlap, and M. J. Burke, "Averaging correlations: Expected values and bias in combined Pearson rs and Fisher's z transformations," *J. Gen. Psychol.*, vol. 125, no. 3, pp. 245–261, 1998.
- [12] A. A. Hagberg, D. A. Schult, and P. J. Swart, "Exploring Network Structure, Dynamics, and Function using NetworkX," in *Proceedings of the 7th Python in Science Conference*, 2008, pp. 11–15.
- [13] G. Csardi and T. Nepusz, "The igraph software package for complex network research," *InterJournal*, vol. Complex Sy, p. 1695, 2006.
- [14] G. A. Pavlopoulos, D. Paez-Espino, N. C. Kyrpides, and I. Iliopoulos, "Empirical comparison of visualization tools for larger-scale network analysis," *Adv. Bioinformatics*, vol. 2017, 2017.
- [15] G. Perrone, J. Unpingco, and H. Lu, "Network visualizations with Pyvis and VisJS," *CoRR*, vol. abs/2006.0, 2020.
- [16] V. E. Krebs, "Mapping networks of terrorist cells," *Connections*, vol. 24, no. 3, pp. 43–52, 2002.
- [17] S. P. Borgatti, "Centrality and network flow," *Soc. Networks*, vol. 27, no. 1, pp. 55–71, 2005.

DETEKSI POLISI TIDUR PADA JALAN MENGGUNAKAN ANILISIS BLOB DAN KONVOLUSIONAL NEURAL NETWORK

Ervin Indra Nugraha, *Informatika Institut Sains dan Teknologi Terpadu Surabaya(ISTTS)*,
Yuliana Melita Pranoto, *Informatika Institut Sains dan Teknologi Terpadu Surabaya(ISTTS)*.

Abstrak— Polisi tidur merupakan pembatas kecepatan laju dari kendaraan yang sengaja ditempatkan diatas jalan. Polisi tidur memiliki dua jenis karakteristi. Polisi tidur memiliki ukuran berbeda yang ditemui pada beberapa perumahan, ditempat ujian sim, dan yang sering dijumpai pada perumahan atau jalan dengan beragam warna yang berbeda. Deteksi polisi tidur pada jalan akan menggunakan dua metode Anilisis blob dan CNN. Proses deteksi polisi tidur akan dilakukan menggunakan anilisis blob, saat metode anilisis blob tidak mendeteksi adanya polisi tidur maka akan dilakukan proses CNN untuk melakukan deteksi. Dalam proses anilisis blob, alur penelitian deteksi akan dilakukan menggunakan anilisis blob, pada saat proses blob tidak mendeteksi adanya polisi tidur maka proses deteksi akan dilanjutkan menggunakan CNN. Sebelum dilakukan proses deteksi menggunakan blob, gambar atau video frame akan diproses menggunakan proses preprosesing, morfologi erosi dan dilasi. Penggunaan proses preprosesing dan morfologi dilakukan agar objek berupa polisi tidur dapat dipisahkan dari gambar background yaitu aspal. Uji coba pada penelitian akan dilakukan pada 10 buah video dengan durasi minimal 30 detik dan 100 gambar polisi tidur yang diproses pada dataset. Pada dataset akan dikelompokan untuk dilakukan klasifikasi yaitu berwarna dan tidak berwarna. Setiap warna polisi tidur yang terdeteksi akan dicatat dan berapa banyak pada warna tersebut polisi tidur dapat dideteksi. Kedua metode yang digabungkan mendapatkan hasil deteksi yang baik dengan hasil 76% terhadap polisi tidur pada perumahan. Pada uji coba rata-rata polisi tidur tanpa warna atau warna yang sama dengan aspal dan penggunaan paving pada jalan mempengaruhi tingkat akurasi dari deteksi polisi tidur.

Kata Kunci—Anilisis blob, CNN, Deteksi Polisi Tidur, Polisi tidur.

I. PENDAHULUAN

Polisi tidur digunakan untuk mengkontrol kecepatan dari kendaraan yang bergerak di jalan, hal tersebut dilakukan untuk membatasi kecepatan dari kendaraan yang melaju sehingga tidak terjadinya kecelakaan yang tidak diharapkan. Pengguna kendaraan kadang juga tidak memperhatikan adanya polisi tidur yang berada di jalan saat mengendarai dengan kecepatan yang tinggi. Adanya polisi tidur membuat pengendara kendaraan memperlambat laju dari kendaraan yang dibawa. Polisi tidur memiliki beberapa ukuran standard yang digunakan untuk tempat tertentu.[1]. Polisi tidur yang dideteksi pada jalanan India memiliki warna yang berbeda. Penelitian banyak dilakukan di jalanan India, dan dilakukan pada 5 kategori polisi tidur sesuai dengan jalan[1].

Ervin Indra Nugraha, Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail: ervinindra1@gmail.com).

Yuliana Melita Pranoto, Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail: ymp@stts.edu).

warna putih kuning, kuning hitam, putih hitam dan tanpa warna. Sampel dari setiap kategori antara lain 300 untuk polisi putih kuning, 200 untuk polisi tidur kuning hitam, 200 untuk polisi tidur hitam, 150 untuk polisi tidur putih hitam, dan 150 untuk polisi tidur tanpa warna. Dari 5 kategori tersebut dapat disimpulkan deteksi polisi tidur menggunakan anilisis blob memiliki tingkat akurasi mencapai 80%[1].

Berdasarkan hasil penelitian, anilisis blob memiliki kemampuan yang baik dalam mendeteksi gambar 2D. Penelitian anilisis blob dapat dipadukan dengan proses segmentasi citra lain seperti *Gaussian Filtering*[2]. Pada penelitian telah mempertimbangkan 4 parameter untuk menentukan kinerja sistem pada tabel hasil analisa. Parameter tersebut antara lain *True Positif*, *True Negatif*, *False Positive*, dan *False Negative*. Hasil analisis dari tiap kategori, yaitu pada kategori 1, 2, 3 dan 4 nilai true positif hampir 90% pada tingkat keakuratan deteksi, sedangkan pada kategori 5 yang mendapatkan hasil yang lebih sedikit.

Pada negara berkembang infrastruktur dan keterbatasan sumber daya membuat negara menderita kondisi jalan yang buruk [3]. Deteksi pada hambatan pada negara berkembang dapat dilakukan menggunakan CNN. Dalam pengujian, model CNN dapat mendeteksi objek yang diinginkan, yaitu lubang pada jalan dan polisi tidur dengan akurasi tinggi. Akurasi pada lubang jalan dengan nilai paling tinggi 99% dan paling rendah adalah 95% sedangkan pada polisi tidur dengan nilai 99%.

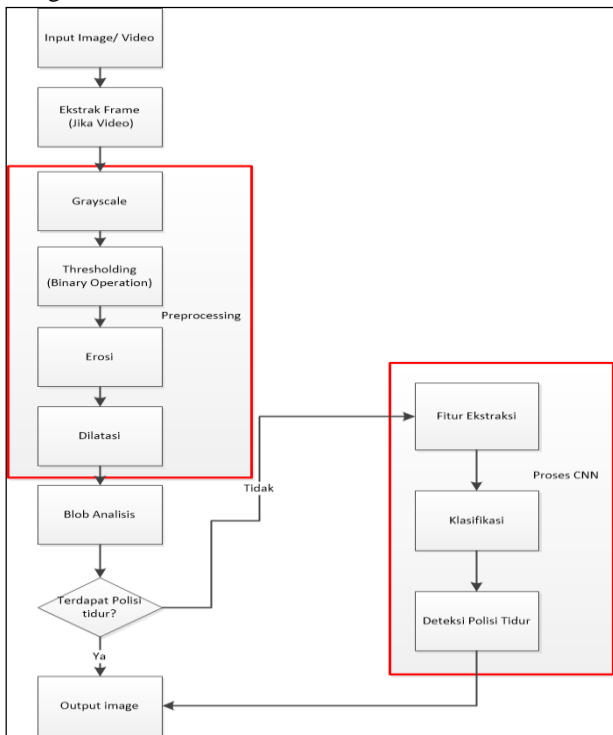
Menurut Sandeep Shaah [4] penggunaan CNN terhadap deteksi polisi tidur dapat membantu untuk mengurangi kecelakaan yang terjadi dalam berkendara di jalan. penelitian dilakukan menggunakan dashcam, Pada penelitian diharapkan sebuah langkah untuk mengurangi jumlah kecelakaan. Penelitian menggunakan *transfer learning* yang digunakan pada data yang telah dilatih menggunakan jaringan saraf dengan memodifikasi layer klasifikasi. Jaringan saraf akan melakukan *training* dan melakukan klasifikasi pada data dengan jumlah 1000 atau lebih yang akan dilakukan selama beberapa minggu. Hasil Klasifikasi dengan network memiliki hasil true positif 88.9%.

Pada pengembangan penelitian lainnya, deteksi pada polisi tidur dapat dikembangkan ke tingkat yang lebih tinggi yaitu *advance driver assistance* [5]. Pada penelitian menghasilkan nilai rata-rata 80% pada polisi tidur berwarna dan 4% pada polisi tidur tanpa warna.

Berdasarkan dari penelitian yang telah ada [6]–[15], anilisis blob dapat secara baik mendeteksi polisi tidur yang memiliki warna yang jelas. Tujuan dari penelitian ini adalah menggabungkan anilisis blob dengan CNN sehingga deteksi polisi tidur dapat lebih efektif untuk mendeteksi polisi tidur berwarna atau tidak berwarna.

II. METODOLOGI PENELITIAN

Pada penelitian menggunakan 2 metode yang digunakan untuk mendeteksi polisi tidur. Dua metode penelitian digunakan untuk melengkapi deteksi sistem dimana metode blob analisis memiliki kelemahan dalam mendeteksi gambar polisi tidur tanpa warna. Metode pertama merupakan deteksi menggunakan analisis blob, dimana deteksi dari input gambar atau video akan dideteksi pixel- pixel yang berhubungan untuk mencari sebuah objek yang telah ditentukan pada penelitian yaitu polisi tidur. Metode kedua merupakan convolutional neural network (CNN), dimana deteksi input gambar atau video akan dideteksi menggunakan metode machine learning. Dibutuhkan dataset untuk menggunakan teknik machine learning convolutional neural network. Pembagian alur penelitian akan dijabarkan beberapa proses. Proses dari alur sistem antara lain proses frame ekstraksi, proses preprosesing, proses thresholding, proses morfologi yaitu meliputi erosi dan dilasi, proses analisis blob dan proses convolutional neural network. Alur penelitian dapat dilihat pada gambar 1.



Gambar. 1. Alur Penelitian Deteksi

A. Ekstrak Frame

Pada tahap pertama penelitian, input pada penelitian dibagi menjadi dua yaitu video dan gambar. Deteksi pada tahap pertama akan dilakukan menggunakan metode analisis blob dimana input akan berupa gambar yang akan dilakukan proses untuk mendeteksi objek polisi tidur pada gambar.

B. Proses Grayscale dan Masking

Pada tahap preperocessing input gambar merupakan input yang berasal dari proses frame ekstraksi, jika input merupakan gambar maka proses ekstraks frame akan dilewati dan gambar akan langsung diproses pada proses preprosesing. Gambar akan diubah menjadi gambar dalam warna grayscale. Gambar akan diubah menjadi grayscale dengan persamaan 2.

$$Grayscale = (0.3 * R) + (0.59 * G) + (0.11 * B) \quad (2)$$

Pada persamaan 2 dapat dijelaskan dimana R adalah nilai intensitas warna pixel merah pada gambar, G adalah nilai intensitas warna pixel hijau gambar, B adalah nilai intensitas warna pixel biru pada gambar. Pada perhitungan grayscale tiap warna pada masing – masing pixel akan dirubah. Warna keseluruhan pada gambar yang terbentuk akan dinormalisasi oleh persamaan grayscale sehingga warna yang dihasilkan pada gambar menjadi berwarna abu- abu. Hasil grayscale dapat dilihat pada gambar 2.



(a)




(b)

Gambar. 2. (a)Gambar input (b) gambar hasil grayscale

Pada gambar 2(b) merupakan hasil grayscale dari gambar input dari penelitian. Pada gambar grayscale merubah warna RGB menjadi keabuan yang digunakan untuk mereduksi noise warna pada gambar input. Noise pada gambar direduksi dengan tujuan agar warna yang tidak dibutuhkan tidak ikut diproses pada proses selanjutnya sehingga tidak memperberat dan memakan banyak resource yang dibutuhkan. Gambar dengan noise yang cenderung banyak membuat deteksi pada analisis blob menjadi tidak baik dan akurat. Pada proses grayscale dilakukan agar gambar menjadi siap untuk dilakukan proses lebih lanjut untuk dilakukan adanya deteksi.



(a)



(b)

Gambar. 3. (a)Masking yang digunakan (b) gambar hasil masking


Pada proses grayscale akan dilakukan proses masking untuk mendeteksi polisi tidur. Masking pada gambar grayscale dilakukan pada posisi jalan bagian bawah dimana polisi tidur tertangkap kamera smartphone. Proses Masking bertujuan agar proses selanjutnya pada penelitian akan memproses gambar jalan yang memiliki polisi tidur saja dan bukan gambar mobil atau pohon. Hasil masking dapat dilihat pada gambar 3.

C. Proses Thresholding

Pada proses thresholding, gambar hasil dari proses masking pada gambar 6(b) akan dilakukan proses thresholding dimana warna pixel yang gelap akan diubah menjadi hitam dan warna yang lebih terang akan diubah menjadi putih. Persamaan thresholding dapat dilihat pada persamaan 3.

$$g(x,y) = \begin{cases} 1, & f(x,y) > T \\ 0, & f(x,y) \leq T \end{cases} \quad (3)$$

pada thresholding bertujuan untuk mengekstrak objek dari background gambar. Patern dari objek yang akan dideteksi akan lebih nampak pada gambar setelah proses thresholding dilakukan. Hasil thresholding ditunjukkan pada gambar 4.



Gambar. 4. Hasil Proses Thresholding

D. Proses Erosi dan Dilasi

Pada proses erosi, pixel pada gambar hasil thresholding akan direduksi atau dikikis untuk menghilangkan noise. Tujuan proses erosi dilakukan agar bentuk objek yang merupakan polisi tidur dapat terlihat dengan jelas pada gambar, sedangkan objek lain yang ikut terekstrak saat proses thresholding dapat menghilang.


Reduksi yang dilakukan pada pixel gambar berwarna putih. Hasil dari penggunaan erosi terhadap gambar hasil thresholding dapat dilihat pada gambar 5.



Gambar. 5. Hasil Erosi

Setelah dilakukan proses erosi, maka akan dilakukan proses

dilasi. Proses dilasi merupakan kebalikan dari proses erosi. Dilasi akan melakukan penebalan terhadap pixel gambar berwarna putih, sehingga objek yang dideteksi akan terlihat lebih jelas pada gambar. Objek yang telah direduksi pixelnya pada proses erosi tidak akan tampil saat gambar dilakukan proses dilasi karena pixel objek telah tereduksi. Pada tahap dilasi gambar pixel dapat digunakan sebagai objek yang akan diproses menggunakan analisis blob apakah objek tersebut polisi tidur atau bukan. Berikut hasil dilasi dapat dilihat pada gambar 6.



Gambar. 6. Hasil Dilasi


E. Analisis Blob

Pada tahap setelah preprocessing adalah tahap analisis blob. Pada tahap analisis blob gambar akan dilakukan deteksi apakah terdapat objek polisi tidur pada gambar atau tidak. Input pada deteksi analisis blob merupakan output dari morfologi dilasi. Pada gambar yang terdapat objek polisi tidur akan dilakukan penandaan letak dari polisi tidur yang ditemukan.

Pada Penelitian analisis blob yang digunakan untuk menentukan adanya polisi tidur pada jalan. Input gambar pada analisis blob merupakan gambar dengan tipe binary, yaitu gambar dengan warna hitam dan putih. Berikut merupakan persamaan matrix gambar yang digunakan dalam analisis blob pada penelitian dilihat pada persamaan 4.

$$H(x, \sigma) = \begin{bmatrix} L_{xx}(x, \sigma) & L_{xy}(x, \sigma) \\ L_{xy}(x, \sigma) & L_{yy}(x, \sigma) \end{bmatrix} \quad (4)$$

Pada persamaan 4 $H_{(x,\sigma)}$ merupakan symbol dari hessian matrix pada titik x pada skala σ . Pada titik yang dilambangkan x memiliki koordinat pada x, y pada gambar yang akan dideteksi. Pada persamaan 4 $L_{xx}(x, \sigma)$ merupakan hasil nilai perkalian terhadap titik x, pada titik xy, dan terhadap titik y. Pada hasil persamaan 4, hessian matrix akan menghasilkan matrix dari gambar yang diinputkan. Matrix yang dihasilkan pada persamaan 4.1 akan dikalikan dengan Gaussian kernel yang akan menghasilkan matrix 3x3 dimana hasil matrix merupakan koordinat dari titik x, koordinat dari titik y, dan ukuran blob pada titik tersebut.



Gambar. 7. Hasil Blob

Pada gambar 7 merupakan hasil analisis blob, pada pixel putih bertanda label lingkaran merah merupakan blob yang dideteksi pada penelitian. Pixel putih dengan lingkaran merah ditandai berdasarkan titik koordinat blob yang ditemukan pada gambar. Hasil yang ditunjukkan pada blob akan disimpan dan diambil titik koordinatnya untuk digambarkan tanda pada letak polisi tidur pada gambar RGB. Hasil pelabelan dapat dilihat pada gambar 8.




Gambar. 8. Hasil Deteksi Polisi Tidur

F. Input Pada CNN

Input pada CNN merupakan frame video atau gambar berwarna dari frame ekstraksi. Pada hasil gambar yang didapat dari frame ekstraksi akan ditampung pada dua variabel berbeda. Pada variabel pertama gambar akan diproses menggunakan proses preprocessing, dan diteruskan pada analisis blob. Saat analisis blob tidak menemukan adanya polisi tidur maka variabel kedua yang berisi gambar RGB akan diteruskan pada proses CNN untuk dideteksi.


G. Convolutional Neural Network (CNN)

Pada tahap CNN, jika polisi tidur tidak dapat dideteksi menggunakan analisis blob, maka CNN akan mendeteksi gambar input pada penelitian. Gambar arsitektur CNN dapat dilihat pada gambar 9.



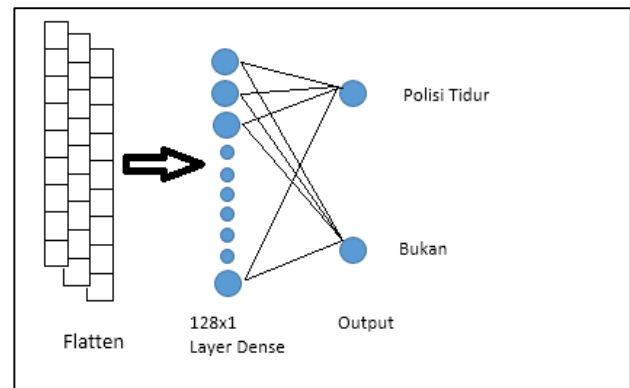
Gambar. 9. Arsitektur CNN

Pada gambar 9 merupakan skema algoritma *Convolutional Neural Network* (CNN) yang digunakan untuk melakukan penelitian. Pada arsitektur CNN dibutuhkan dua proses untuk CNN perlu dilakukan *training* data sebelum dapat digunakan untuk klasifikasi. Pada fase *training*, peneliti mengumpulkan gambar yang berbeda sesuai dengan klasifikasi yang diinginkan. Proses *training* akan dilakuakn berulang untuk beberapa kali sampai hasil dari perhitungan menjadi lebih optimal untuk melakukan deteksi terhadap polisi tidur. Pada gambar 9 terdapat layer-layer yang dapat digunakan untuk melakukan klasifikasi terhadap suatu gambar 2 dimensi.



Gambar. 10. Proses Konvolusi CNN

Pada gambar 10 merupakan proses fitur ekstraksi atau konvolusi, yang dibutuhkan sebuah filter gambar yang dapat disebut sebagai kernel untuk dilakukan proses konvolusi yang dengan ukuran tertentu terhadap gambar. Kernel pada metode convolutional neural network, memiliki ukuran yang dapat digunakan antara lain yaitu 3x3, 5x5, 7x7 dan sebagainya sesuai dengan penelitian yang dilakukan peneliti.



Gambar. 11. Proses Klasifikasi CNN

Pada gambar 11 merupakan gambar proses *fully connected* pada metode CNN. Pada gambar 11 terdapat tiga layer yaitu input layer, layer dense, dan output layer yang digunakan untuk melakukan klasifikasi. Hasil dari proses konvolusi yang merupakan layer dua dimensi akan diubah menjadi satu dimensi pada proses flatten. Pada layer pertama, pada gambar 11 memiliki 3 channel yaitu dikarenakan gambar input pada penelitian merupakan gambar RGB. Pada hidden layer pertama merupakan layer dense dengan ukuran layer 128x1, ukuran pada layer dense disesuaikan dengan ukuran layer flatten yaitu satu dimensi. Layer input akan dilakukan perbandingan terhadap nilai pixel pada hasil flatten tersebut pada layer dense 128x1. Pada layer terakhir merupakan class objek yang akan digunakan sebagai klasifikasi dalam penelitian, yaitu berupa class jenis polisi tidur atau bukan.

III. UJI COBA

Pada penelitian akan dilakukan uji coba terhadap 10 buah video dan 100 gambar pada dataset CNN. Percobaan deteksi dilakukan secara realtime terhadap video yang diinputkan. Pada deteksi, akan diinputkan satu video jalan pada perumahan yang akan dilakukan deteksi, apakah terdapat polisi tidur pada jalan perumahan. Pada perumahan disurabaya memiliki beberapa jenis polisi tidur yang sering dijumpai pada saat melakukan penelitian. Jenis polisi tidur yang dijumpai tersebut antara lain merupakan polisi tidur dengan warna garis hitam putih, garis kuning biru, garis putih kuning dan tanpa warna. Hasil uji coba akan dibahas pada metode analisis blob terlebih dahulu.

Pada penelitian, hasil akan dikategorikan sesuai dengan warna pada polisi tidur yang ditemukan. Hasil thresholding dari grayscale gambar input polisi tidur dengan warna putih hitam, kuning biru, kuning putih, kuning hitam, dan tanpa warna memiliki hasil yang berbeda. Pada polisi tidur yang memiliki warna putih memiliki hasil blob yang cenderung lebih banyak dibanding dengan polisi tidur tanpa warna, hal tersebut yang dapat digunakan untuk menampilkan hasil kategori terhadap warna pada penelitian.

TABEL III
HASIL DETEKSI BLOB ANALISIS

KATEGORI	Jumlah	Terdeteksi	Gagal
Putih Hitam	21	20	1
Kuning Biru	14	14	0
Kuning Putih	15	11	4
Kuning Hitam	13	2	11
Tanpa Warna / Pudar	12	3	8

Pada tabel 3 merupakan hasil deteksi hanya dilakukan pada polisi tidur dengan warna dan polisi tidur dengan warna pudar atau tanpa warna. Pada hasil ringkasan deteksi blob terdapat lima jenis polisi tidur yang ditemukan pada perumahan, antara lain putih hitam, kuning biru, kuning putih, kuning hitam dan pudar atau tanpa warna. Dapat dilihat analisis blob dapat mendeteksi polisi tidur yang memiliki warna yang terang dibanding dengan warna dari background polisi tidur yaitu warna aspal.

TABEL IV
HASIL DETEKSI CNN

KATEGORI	Jumlah	Terdeteksi	Gagal
Putih Hitam	21	21	0
Kuning Biru	14	14	0
Kuning Putih	15	13	2
Kuning Hitam	13	10	3
Tanpa Warna / Pudar	12	5	7

Pada tabel 4 merupakan hasil deteksi yang dilakukan pada polisi tidur dengan warna dan warna pudar atau tanpa warna menggunakan metode CNN saja. Pada hasil ringkasan deteksi CNN dilakukan pada lima jenis polisi tidur yang sama pada tabel 3. Dapat dilihat hasil CNN memiliki peningkatan pada polisi tidur pada kategori kuning putih, kuning hitam, dan tanpa warna pada deteksi blob ditabel 3. Hasil dari deteksi polisi tidur pada kedua proses CNN dan analisis blob akan dipadukan, dan dideteksi lagi menggunakan kedua metode yang digabungkan. Hasil deteksi CNN dan analisis blob dapat dilihat pada tabel 5.






TABEL V
HASIL DETEKSI BLOB ANALISIS DAN CNN

KATEGORI	Jumlah	Terdeteksi	Gagal
Putih Hitam	21	20	1
Kuning Biru	14	14	0
Kuning Putih	15	14	1
Kuning Hitam	13	10	3
Tanpa Warna / Pudar	12	6	6

Pada tabel 5 merupakan hasil dari deteksi polisi tidur menggunakan dua metode yaitu analisis blob dan CNN. Pada






hasil percobaan, polisi tidur yang gagal dideteksi lebih sedikit dibanding dengan hasil pada tabel 3 dan tabel 4. Pada hasil tabel percobaan, saat analisis blob tidak dapat mendeteksi polisi tidur maka proses CNN yang akan menangani deteksi sehingga kegagalan untuk mendeteksi polisi tidur dapat diminimalkan. Pada kategori kelima merupakan polisi tidur dengan warna pudar atau tanpa warna yang juga dideteksi menggunakan metode analisis blob dan CNN.

TABEL VI
HASIL OUTPUT DETEKSI

No.	Hasil
1	
2	
3	
4	
5	

Pada tabel 6 merupakan tabel gambar polisi tidur terkait yang dapat dideteksi oleh metode analisis blob. Dapat dilihat hasil dari labeling polisi tidur dapat membingkai polisi tidur yang tepat berada pada jalan dengan tepat ditengah. Hasil deteksi membuktikan blob analisis memiliki kemampuan yang baik dalam mengenali objek polisi tidur dengan warna yang lebih terang yaitu dalam arti tidak pudar atau tanpa warna

TABEL VII
HASIL OUTPUT DETEKSI

No.	Hasil
1	
2	
3	
4	
5	

Pada tabel 7 merupakan tabel gambar polisi tidur terkait yang dapat dideteksi oleh metode CNN. Pada hasil deteksi polisi tidur akan ditandai menggunakan persegi panjang berwarna hijau. Pada kelima gambar tersebut merupakan salah satu dari output deteksi terhadap gambar yang melibatkan kelima polisi tidur. Dapat dilihat hasil ketiga merupakan polisi tidur yang pudar yang dapat dideteksi oleh CNN. Hasil deteksi membuktikan CNN memiliki kemampuan yang baik dalam mengenali objek polisi tidur dengan warna yang pudar. Dapat dilihat CNN memiliki tingkat akurasi yang baik untuk mendeteksi polisi tidur yang tidak dapat dideteksi oleh metode blob analisis

IV. KESIMPULAN

Berdasarkan hasil penelitian Deteksi Polisi Tidur Pada Jalan Menggunakan Analisis blob dan Convolutional Neural Network, analisis blob dapat dengan baik mendeteksi objek polisi tidur dengan warna yang lebih terang dari background yaitu aspal. Hasil deteksi memiliki tingkat akurasi yang baik saat CNN dipadukan dengan analisis blob, sehingga hampir setiap polisi tidur yang ditemui dapat dideteksi. Berikut merupakan poin kesimpulan pada penelitian.

- Analisis blob memiliki kemampuan yang baik dalam melakukan deteksi terhadap polisi tidur dengan jenis warna yang lebih terang dari background polisi tidur yaitu aspal .
- Dengan adanya CNN yang dipadukan dengan analisis blob, deteksi polisi tidur dapat mengurangi gagal deteksi yang dikarenakan kelemahan analisis blob dalam mendeteksi polisi tidur dengan warna pudar/ tanpa warna.
- Tingkat akurasi pada deteksi menggunakan dua metode yaitu analisis blob dan CNN memiliki tingkat akurasi 76% untuk mendeteksi polisi tidur dalam lingkup perumahan.

Penelitian masa mendatang akan dikembangkan lebih jauh pada metode yang digunakan, cara memisahkan polisi tidur dari background atau jalan aspal, dan penelitian dapat dikembangkan ke tingkat advance driver assistance dimana mobil dapat melambat saat melaju kearah polisi tidur atau adanya pengingat jika akan menabrak polisi tidur dengan kecepatan tinggi.

DAFTAR PUSTAKA

- [1] B. Manikandan and M. Bharathi, "SPEED BREAKER DETECTION USING BLOB ANALYSIS," *Int. J. Pure Appl. Math.*, vol. 118, no. 20, pp. 3671–3677, 2018.
- [2] D. P. W., N. Babu C, and T. Srihari, "Real Time Speed Bump Detection Using Gaussian Filtering and Connected Component Approach," *Circuits Syst.*, vol. 07, pp. 2168–2175, 2016, doi: 10.4236/cs.2016.79188.
- [3] Z. Hasan, S. N. Shampa, T. R. Shahidi, and S. Siddique, "Pothole and Speed Breaker Detection Using Smartphone Cameras and Convolutional Neural Networks," in *2020 IEEE Region 10 Symposium (TENSYP)*, 2020, pp. 279–282.
- [4] S. Shah and C. Deshmukh, "Pothole and bump detection using convolution neural networks," in *2019 IEEE Transportation Electrification Conference (ITEC-India)*, 2019, pp. 1–4.
- [5] D. P. W., N. Babu C, and S. Tharumar, "Advance Driver Assistance System (ADAS) – Speed Bump Detection," 2015, doi: 10.13140/RG.2.1.2412.3285.
- [6] Y. Bhatia, R. Rai, V. Gupta, N. Aggarwal, A. Akula, and others, "Convolutional neural networks based potholes detection using thermal imaging," *J. King Saud Univ. Inf. Sci.*, 2019.
- [7] C. Chun and S.-K. Ryu, "Road surface damage detection using fully convolutional neural networks and semi-supervised learning," *Sensors*, vol. 19, no. 24, p. 5501, 2019.
- [8] J. Dhameeshkar, S. A. Aniruthan, R. Karthika, L. Parameswaran, and others, "Deep Learning based Detection of potholes in Indian roads using YOLO," in *2020 International Conference on Inventive Computation Technologies (ICICT)*, 2020, pp. 381–385.
- [9] T. Jia, N. Sun, and M. Cao, "Moving object detection based on blob analysis," in *2008 IEEE International Conference on Automation and Logistics*, 2008, pp. 322–325.
- [10] H. Maeda, Y. Sekimoto, T. Seto, T. Kashiyama, and H. Omata, "Road damage detection using deep neural networks with images captured through a smartphone," *arXiv Prepr. arXiv1801.09454*, 2018.
- [11] K. Vigneshwar and B. H. Kumar, "Detection and counting of pothole using image processing techniques," in *2016 IEEE International Conference on Computational Intelligence and Computing Research (ICCIC)*, 2016, pp. 1–4.
- [12] M. D. Yusuf, R. D. Kusumanto, Y. Oktarina, T. Dewi, and P. Risma, "Blob analysis for fruit recognition and detection," *Comput. Eng. Appl. J.*, vol. 7, no. 1, pp. 23–32, 2018.
- [13] V. Varma, S. Adarsh, K. I. Ramachandran, and B. B. Nair, "Real

time detection of speed hump/bump and distance estimation with deep learning using GPU and ZED stereo camera,” *Procedia Comput. Sci.*, vol. 143, pp. 988–997, 2018.

- [14] D. K. Dewangan and S. P. Sahu, “Deep learning-based speed bump detection model for intelligent vehicle system using raspberry Pi,” *IEEE Sens. J.*, vol. 21, no. 3, pp. 3570–3578, 2020.
- [15] K. M. Lion, K. H. Kwong, and W. K. Lai, “Smart speed bump detection and estimation with kinect,” in *2018 4th International Conference on Control, Automation and Robotics (ICCAR)*, 2018, pp. 465–469.

Deteksi Pemakaian Helm Proyek Dengan Metode Convolutional Neural Network

Bambang Widodo, *Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya(ISTTS)*,
Hendrawan Armanto, *Informatika Institut Sains dan Teknologi Terpadu Surabaya(ISTTS)*,
Endang Setyati, *Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya(ISTTS)*.

Abstrak— Penggunaan helm proyek pada pekerjaan dengan resiko kecelakaan tinggi seperti pekerjaan konstruksi seringkali diabaikan oleh pekerja, sehingga apabila terjadi kecelakaan kerja yang tidak diinginkan seperti kejatuhan benda keras dari atas atau terjadi benturan keras pada kepala akan berakibat fatal bagi pekerja tersebut. Penelitian ini bertujuan untuk mendeteksi pemakaian helm proyek oleh pekerja konstruksi pada citra. Metode yang digunakan pada penelitian ini adalah *Convolutional Neural Network YOLO*. Sistem terdiri dari tiga proses utama yaitu proses *pre processing*, proses *training* dan proses deteksi. Proses *pre processing* adalah melakukan *resize* dan anotasi *labeling* pada citra dataset. Selanjutnya adalah proses *training* pada dataset dengan menggunakan *transfer learning YOLOv2*. Pada proses deteksi digunakan 4 buah *anchor box* pada setiap *grid* pada citra, hasil dari mencari nilai ukuran *bounding box* yang memiliki *IOU* terbaik dengan melakukan proses *clustering* pada dataset training dan validasi yang terdapat *bounding box* menggunakan algoritma *K-Mean clustering*. Algoritma *Intersection Over Union (IOU)* dan *Non Max Suppression (NMS)* digunakan agar *bounding box* prediksi yang dibuat presisi dengan objek yang berhasil dideteksi dan untuk menghilangkan multideteksi pada objek yang sama. Proses deteksi pada sistem ini melakukan lokalisasi dan klasifikasi dengan sekali langkah proses sehingga hasil dari proses deteksi ini adalah orang menggunakan helm proyek dan orang tidak menggunakan helm proyek. Pengujian sistem deteksi dilakukan secara individu maupun kelompok maksimal 5 orang dengan *F1-score* yang diperoleh sebesar 0,79.

Kata Kunci—*Bounding Box, CNN, Helm Proyek, YOLO*

I. PENDAHULUAN

Helm adalah alat pelindung kepala yang berfungsi melindungi kepala dari benturan sehingga kepala tidak mengalami cedera. Beberapa kegiatan manusia yang menggunakan helm untuk melindungi kepala diantaranya

Bambang Widodo, Departemen Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail: bamb.inside@gmail.com)

Hendrawan Armanto, Departemen Informatika, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail: hendrawan@stts.edu)

Endang Setyati, Departemen Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail: endang@stts.edu)

adalah mengendarai kendaraan bermotor roda dua, melakukan pekerjaan konstruksi, beberapa kegiatan olah raga dan lain sebagainya.

Untuk pekerjaan konstruksi para pekerja diwajibkan menggunakan alat keselamatan kerja, helm proyek adalah salah satu alat keselamatan kerja yang wajib digunakan, hal tersebut sebagai salah satu tujuan penting dan harus dipatuhi oleh pekerja konstruksi dalam K3 (Keselamatan dan Kesehatan Kerja). Akan tetapi masih banyak pekerja konstruksi yang tidak menggunakan helm proyek pada saat bekerja. Mereka menggunakan helm yang sudah disediakan hanya apabila ada pengawasan dari supervisor atau penyelia, akan tetapi bila supervisor tersebut tidak berada di lokasi, sering diantara para pekerja melepas helmnya, padahal hal tersebut sangat berbahaya dan bisa berakibat fatal bila terjadi suatu insiden yang tidak diinginkan seperti kejatuhan benda keras dari atas atau terjadi benturan keras yang mengakibatkan cedera pada kepala.

Pada penelitian ini menggunakan metode *Convolutional Neural Network (CNN) YOLO*. *Convolutional Neural Network (CNN) YOLO* adalah salah satu metode *Deep learning (DL)* dan dapat digunakan untuk mendeteksi dan mengenali suatu objek pada sebuah citra sehingga diharapkan dapat mendeteksi pekerja yang menggunakan helm proyek dan yang tidak menggunakan helm proyek.

II. TINJAUAN PUSTAKA

Pada tahun 2017 Jimit Mistry, Aashish K. Misraa, Meenu Agarwal, Ayushi Vyas, Vishal M. Chudasama dan Kishor P. Upla telah melakukan penelitian untuk melakukan deteksi orang menggunakan helm dan orang tidak menggunakan helm pada pengendara sepeda motor beserta ekstraksi plat nomor menggunakan *Convolutional Neural Network (CNN)*[1]. Penelitian ini diterbitkan di Jurnal IEEE 2017. Peneliti menggunakan dua model *YOLOv2*[2], salah satunya untuk mendeteksi pengendara sepeda motor yang memakai helm dan yang tidak memakai helm. Model *YOLOv2* pertama dilatih dengan dataset *COCO*[3] yang mendeteksi jumlah kelas dalam suatu gambar. Gambar kelas orang yang telah dipotong dari *YOLOv2* pertama digunakan sebagai input untuk model *YOLOv2* kedua yang selanjutnya dilatih dengan dataset helm. Dataset helm ini terdiri dari gambar helm saja.

Untuk deteksi orang menggunakan dataset *COCO*, untuk tahap kedua deteksi helm menggunakan dataset 3054 gambar helm. Untuk tahap *testing* dataset gambar menggunakan helm dan tidak menggunakan helm diunduh dari *ImageNet*[4]. Dataset testing adalah 409 gambar memakai helm dan 403 gambar tidak memakai helm. Hasil akurasi dari penelitian ini adalah 94,7% pada 2500 iterasi.

Pada tahun 2015 Xiaogang Chen, Pengxu Wei, Wei Ke, Qixiang Ye dan Jianbin Jiao melakukan penelitian deteksi pejalan kaki dengan Deep Convolutional Neural Network (Deep-CNN)[5] yang diterbitkan di Springer International Publishing Switzerland. Dalam penelitian ini, *Aggregated Channel Features (ACF)* dan *Deep Convolutional Neural Networks (DCNN)* digunakan untuk mendeteksi pejalan kaki dengan fitur yang sangat kompleks secara efisien dan efektif. ACF digunakan untuk menghasilkan kandidat windows pejalan kaki dan DCNN digunakan untuk klasifikasi. Eksperimen yang dilakukan memiliki peforma yang baik untuk dataset INRIA[6].


Pada tahun 2016 Sugianto dari Institut Sains dan Teknologi Terpadu Surabaya melakukan penelitian deteksi alat pelindung kepala (helm) menggunakan metode *Haar Cascade Classifier*[7]. Sistem terdiri dari dua proses utama yaitu proses *training* data dan proses deteksi. Pada proses *training* terdapat empat proses, yaitu *haar-like feature*, citra integral, *ada-boost* dan *cascade classifier*. *Haar-like feature* merupakan kumpulan fitur khusus yang mempresentasikan kepala, wajah dan helm. Citra integral adalah cara cepat menghitung *haar feature*, sedangkan *ada-boost* adalah pembobotan secara statistik nilai-nilai fitur yang didapat dan di-filter menggunakan *cascade classifier*.

Dataset yang digunakan adalah 1026 dataset positif dan 1627 dataaset negatif, dataset positif berupa citra manusia dengan menggunakan helm dan dataset negatif adalah citra yang bukan manusia menggunakan helm (citra *background* dan pemandangan). Hasil uji coba pada 20 frame video dengan 7 skenario adalah akurasi sebesar 92% untuk uji coba individu dan akurasi sebesar 71% untuk uji coba kelompok.

Selanjutnya adalah beberapa teori penunjang yang digunakan dalam penelitian ini.

A. Artificial Neural Network (ANN)

Artificial Neural Network (ANN) merupakan suatu model komputasi paralel yang meniru fungsi dari sistem jaringan syaraf biologi otak manusia. Dalam otak manusia terdiri dari milyaran neuron yang saling berhubungan. Hubungan ini disebut dengan *Synapses*. Komponen neuron terdiri dari satu inti sel yang akan melakukan pemrosesan informasi, satu akson (*axon*) dan minimal satu *dendrit*. Informasi yang masuk akan diterima oleh *dendrit*. Selain itu, *dendrit* juga menyertasi akson sebagai keluaran dari suatu pemrosesan informasi.. Struktur dasar dari Jaringan Syaraf Tiruan terdiri dari 3 jenis layer utama, yaitu input, hidden, dan output layer [8]




Gambar.1. Struktur Artificial Neural Network (ANN)

B. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN)[9] telah memiliki terobosan hasil yang baik selama dekade terakhir di berbagai bidang yang terkait dengan pengenalan pola; dari pemrosesan gambar hingga ke pengenalan suara. Aspek yang paling bermanfaat dari CNN adalah mengurangi

jumlah parameter dalam *Artificial Neural Network (ANN)*. Prestasi ini telah mendorong peneliti dan pengembang untuk melakukan pendekatan model yang lebih besar untuk menyelesaikan tugas-tugas kompleks, yang tidak mungkin dilakukan dengan ANN klasik. Aspek penting lain dari CNN, adalah untuk memperoleh fitur abstrak saat input merambat ke lapisan yang lebih dalam. Misalnya, dalam klasifikasi gambar, tepi citra mungkin terdeteksi di lapisan pertama, dan kemudian bentuk lebih sederhana di lapisan kedua, dan kemudian fitur dengan tingkat yang lebih tinggi seperti wajah di lapisan selanjutnya.

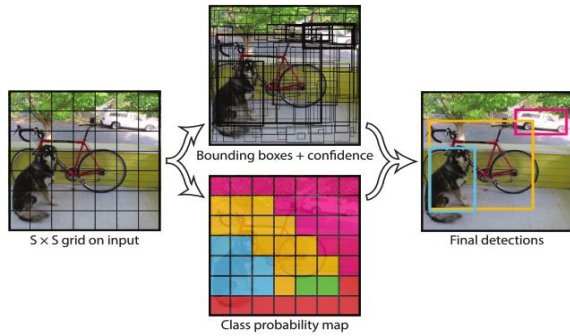


Gambar.2. Learned Fiture Dari Sebuah CNN

C. You Only Look Once (YOLO)

You Only Look Once atau YOLO[10], akan membagi inputan citra menjadi grid berukuran $S \times S$, dimana nilai S adalah 7 dengan input gambar berukuran 448×448 . Jika titik tengah koordinat pada GT (*Ground Truth*) suatu objek berada di dalam *grid*, maka *grid* tersebut bertanggung jawab untuk mendeteksi suatu objek. Setiap grid sel memprediksi B *bounding box* dan *confidence score* untuk kotak tersebut[11]. *Confidence score* ini mencerminkan seberapa yakin model tersebut bahwa di dalam *bounding box* berisi objek dan juga nilai akurasi prediksinya. Untuk mendapatkan *bounding box* prediksi, akan dilakukan konvolusi dari inputan citra, sehingga hasil akhirnya akan mendapat ukuran *bounding box* sebesar $S \times S \times (B \times 5 + C)$ dimana B adalah banyaknya *bounding box* (umumnya 2) dalam 1 *grid* dan C adalah banyaknya kelas yang dapat diklasifikasi. Nilai B dikalikan dengan 5 karena sebuah *bounding box* memiliki 5 nilai yang perlu disimpan, koordinat x , koordinat y , lebar (*width*), tinggi (*height*), dan *confidence score* (nilai probabilitas *bounding box* yang bersangkutan memiliki sebuah objek).


Untuk semua atribut pada *bounding box* akan dilakukan normalisasi sehingga nilainya menjadi antara 0 hingga 1. Koordinat x dan y akan dinormalisasi menyesuaikan titik kiri atas dari *grid* yang bersangkutan. Dan tinggi dan lebar akan dinormalisasi sesuai dengan ukuran gambar (lebar dan tinggi). Nilai koordinat x dan y pada sebuah *bounding box* pada setiap *grid* merupakan titik tengah *grid* yang bersangkutan. Ilustrasi YOLO dapat dilihat pada Gambar 3.



Gambar.3. Model YOLO

D. Intersection Over Union (IOU)

Intersection over Union (IOU) merupakan metode evaluasi untuk mengukur akurasi deteksi objek terhadap suatu dataset[12]. IOU membutuhkan 2 area yang akan diiris dan digabung, 2 area tersebut adalah area *ground-truth bounding box* yang merupakan *bounding box* aktual dan area yang dideteksi dari model yang dibuat[13]. Setiap *bounding box* terdiri dari 5 prediksi: x, y, w, h, dan *confidence*. Koordinat (x; y) adalah pusat *grid* sel pada *bounding box*. Lebar dan tinggi (w dan h) adalah ukuran dari citra. Prediksi *confidence* adalah IOU (*Intersection Over Union*) antara *predicted bounding box* dan *ground truth bounding box*. Setiap *grid* sel juga memprediksi probabilitas kelas bersyarat C , $\Pr(\text{Class}_i|\text{Object})$. Probabilitas ini dikondisikan pada sel *grid* yang berisi objek. Sistem hanya memprediksi satu set probabilitas kelas pada setiap *grid* sel, terlepas dari jumlah B box. Pada saat pengujian sistem mengalikan probabilitas kelas bersyarat dan *box confidence prediction*, yang memberi nilai *confidence* pada kelas untuk setiap *bounding box*.



Gambar.4. Intersection Over Union (IOU)

E. Non Max Suppression (NMS)

Non Max Suppression (NMS)[14] digunakan untuk menyeleksi *bounding box* yang muncul berlebihan pada objek yang sama dengan membandingkan nilai *confidence* masing-masing *bounding box*, hanya nilai *confidence* yang paling tinggi (maksimal) yang akan dipertahankan.

Algoritma Non Max Suppression :

1. Pilih proposal dengan skor *confidence* tertinggi, hapus dari B dan tambahkan ke dalam daftar proposal final D . (Awalnya D kosong).
2. Sekarang bandingkan proposal ini dengan semua proposal - hitung IOU (*Intersection over Union*) proposal ini dengan setiap proposal lainnya. Jika IOU lebih besar dari ambang N , hapus proposal tersebut dari B .

3. Sekali lagi ambil proposal dengan *confidence* tertinggi dari proposal yang tersisa di B dan hapus dari B dan tambahkan ke D .
4. Sekali lagi hitung IOU proposal ini dengan semua proposal di B dan hilangkan kotak yang memiliki IOU tinggi dari ambang batas.
5. Proses ini diulangi sampai tidak ada lagi proposal yang tersisa di B .

Dibawah ini adalah *pseudo-code Non Max Suppression* :

Algorithm 1 Non-Max Suppression

```

1: procedure NMS( $B, c$ )
2:    $B_{nms} \leftarrow \emptyset$ 
3:   for  $b_i \in B$  do
4:      $discard \leftarrow \text{False}$ 
5:     for  $b_j \in B$  do
6:       if  $\text{same}(b_i, b_j) > \lambda_{nms}$  then
7:         if  $\text{score}(c, b_j) > \text{score}(c, b_i)$  then
8:            $discard \leftarrow \text{True}$ 
9:       if not  $discard$  then
10:         $B_{nms} \leftarrow B_{nms} \cup b_i$ 
11:   return  $B_{nms}$ 

```

Gambar.5. Pseudo-code Non Max Suppression

F. Akurasi

Perhitungan tingkat akurasi menggunakan *precision*, *recall* dan *F1-score*[15]. *Precision* adalah tingkat ketepatan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh sistem. *Recall* adalah tingkat keberhasilan sistem dalam menemukan sebuah informasi. *F1-score* adalah ukuran akurasi sebuah uji coba.

$$Precision = \frac{\text{true positive}}{\text{true positive} + \text{false positive}} \quad (1)$$

$$Recall = \frac{\text{true positive}}{\text{true positive} + \text{false negative}} \quad (2)$$

$$F1\text{-score} = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (3)$$


- *True Positive* adalah jumlah objek yang berhasil terdeteksi
- *False positive* adalah jumlah objek yang terdeteksi namun bukan objek yang benar
- *False negative* adalah jumlah objek yang tidak terdeteksi tetapi objek yang benar

III. PERANCANGAN

Pada Bab Perancangan ini akan dibahas mengenai desain alur kerja dari sistem dan algoritma yang akan digunakan.

A. Alur Sistem

Alur sistem yang digunakan pada penelitian ini ditunjukkan pada gambar 6. Proses awal adalah *resize* dan *labeling* citra lalu melakukan *training* dengan *transfer learning* menggunakan *pre trained model YOLOv2* menghasilkan bobot baru. Selanjutnya bobot baru digunakan untuk melakukan proses deteksi orang memakai helm proyek dan orang tidak memakai helm proyek pada citra uji coba.



Gambar.6. Alur Sistem

B. Pre Processing


Pada tahap pre processing semua citra dataset dirubah ukurannya menjadi 448 x 448 piksel serta dilakukan proses *labeling* atau anotasi dengan menggunakan program *labelImg*.

C. Training

Dataset hasil anotasi selanjutnya digunakan untuk proses *training* dengan YOLOv2 menggunakan *transfer learning* untuk mendapatkan bobot baru, yaitu dengan menggunakan bobot *pre trained model* yang sudah dilatih untuk mengenali objek baru. *Pre trained model* yang digunakan adalah bobot YOLOv2 dijalankan pada Google Colaboratory, *epoch* dan *batch size* pada proses training 100 dan 64, sedangkan bobot baru yang dihasilkan akan digunakan untuk mendeteksi orang memakai helm proyek dan orang tidak memakai helm proyek.

D. Klasifikasi dan Lokalisasi

Klasifikasi citra adalah pengkategorian suatu citra ke dalam suatu kategori atau kelas tertentu sedangkan lokalisasi citra adalah menentukan letak atau posisi dari suatu objek didalam citra tersebut dengan *bounding box*. Deteksi objek pada citra adalah penggabungan dari klasifikasi dan lokalisasi beberapa objek dalam satu citra. Untuk klasifikasi dan lokalisasi citra hanya bisa untuk satu objek sedangkan pada deteksi objek pada citra bisa digunakan untuk lebih dari satu objek. Pada algoritma YOLO, dilakukan proses klasifikasi terlebih dahulu baru proses lokalisasi dengan menambahkan *bounding box* pada objek kelas yang terdeteksi dalam sekali proses deteksi.

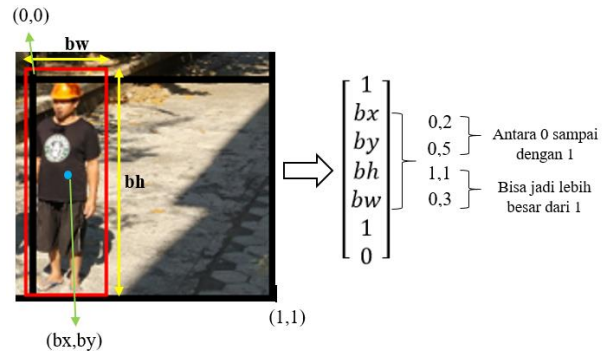


Gambar.7. Proses Deteksi Objek Dengan 2 Kelas

E. Prediksi Bounding Box

Untuk menentukan *bounding box* dari sebuah *grid* pada citra, maka didefinisikan koordinat sebuah *grid* pada citra adalah (0,0) terletak di atas kiri dan (1,1) terletak di bawah kanan. Pada Gambar 7 titik tengah *bounding box* berupa titik berwarna biru, disini mewakili *bx* dan *by*. Nilai *bx* dan *by* antara 0 sampai dengan 1 dari sebuah *grid*, untuk nilai *bx*


dicari dengan cara mengukur dari titik (0,0) kearah kanan sampai dengan tepi kanan *grid* pada titik (1,1). Disini nilai *bx* = 0,2. Sedangkan nilai *by* dicari dengan cara mengukur dari titik (0,0) kearah bawah sampai dengan tepi bawah *grid* pada titik (1,1). Nilai *by* = 0,5. Untuk nilai *bw* adalah lebar *bounding box* dibandingkan dengan lebar *grid*, tinggi dan lebar *grid* didefinisikan 1 jadi nilai *bw* = 0,3. Nilai *bh* adalah tinggi *bounding box* dibandingkan dengan tinggi *grid*, nilai *bh* = 1,1 karena tinggi dari *bounding box* melebihi tinggi dari *grid*. Untuk nilai *bx* dan *by* adalah antara 0 sampai dengan 1, sedangkan untuk nilai *bh* dan *bw* bisa jadi lebih besar dari 1 atau melebihi ukuran tinggi dan lebar dari *grid*.



Gambar.8. Menentukan *Bounding Box* Pada Citra

F. Intersection Over Union (IOU)


IOU dihitung dari luas area irisan dibagi luas gabungan dari *bounding box ground truth* (warna merah) dan *bounding box* prediksi (warna biru). Bila perbandingan rasio atau IOU antara *bounding box* prediksi dan *bounding box ground truth* adalah 1, maka dikatakan IOU sangat sempurna karena tujuan dari *bounding box* prediksi adalah sama atau mendekati *bounding box ground truth*. Untuk nilai hasil IOU sama atau lebih besar dari 0,5 bisa dikatakan *bounding box* prediksi sudah cukup tepat dalam membuat *bounding box* pada objek. Penentuan nilai *threshold* akan berpengaruh pada hasil lokalisasi objek pada citra. Bila *threshold* terlalu tinggi maka bisa berakibat jumlah objek yang terdeteksi lebih sedikit dari jumlah objek yang sebenarnya, sedangkan bila *threshold* terlalu rendah bisa berakibat satu objek dideteksi oleh beberapa *bounding box*.



Gambar.9. Area Irisan *Bounding Box Ground Truth* dan *Bounding Box* Prediksi (a), Area Gabungan *Bounding Box Ground Truth* dan *Bounding Box* Prediksi (b)

G. Non Max Suppression (NMS)

Salah satu kendala dalam deteksi objek adalah ada kemungkinan *multiple* deteksi pada satu objek. Satu objek tidak dideteksi sebagai satu objek tapi dideteksi berkali-kali dan dikenali sebagai lebih dari satu objek sehingga akurasi dari deteksi objek akan rendah. Untuk mengatasi permasalahan tersebut maka digunakan *Non Max Suppression* (NMS). *Non Max Suppression* (NMS) bekerja dengan cara membersihkan *bounding box* prediksi yang mempunyai nilai probabilitas terendah dan mengambil satu *bounding box* prediksi yang mempunyai nilai probabilitas tertinggi. Bila *threshold Non Max Suppression* ditentukan 0,6 maka setelah melalui proses *Non Max Suppression* akan diambil *bounding box* dengan nilai probabilitas tertinggi yaitu 0,8 untuk objek orang tidak memakai helm proyek (*bounding box* warna merah) dan 0,9 untuk objek orang memakai helm proyek (*bounding box* warna kuning).



Gambar.10. Proses *Non Max Suppression* Pada *Bounding Box*

H. Anchor Box

Sebuah *grid* pada citra, hanya dapat mendeteksi satu objek. Bila dalam satu *grid* terdapat dua buah objek atau lebih, maka dapat digunakan *anchor box*. Pada penelitian ini menggunakan 4 buah *anchor box*, hasil dari mencari nilai ukuran *bounding box* yang memiliki IOU terbaik dengan melakukan proses *clustering* pada dataset training dan validasi yang terdapat *bounding box* menggunakan algoritma *K-Mean clustering*[16].

TABEL I
UKURAN 4 BUAH ANCHOR BOX

No	Lebar	Tinggi	Ukuran
1	0,06505013	0,24317773	Sangat Kecil
2	0,10062081	0,45632851	Kecil
3	0,29744874	0,75714696	Besar
4	0,16295355	0,6445702	Sedang

IV. PENGUJIAN DAN ANALISIS

A. Dataset

Dataset yang digunakan dalam penelitian ini adalah citra orang memakai helm proyek (diambil dari dataset VOC2028) sebanyak 1500 citra yang dibagi menjadi 1200 citra untuk data pelatihan dan 300 citra untuk data validasi serta dataset orang tidak memakai helm proyek (diambil dari dataset INRIA) sebanyak 1500 citra yang dibagi menjadi 1200 citra untuk data pelatihan dan 300 citra untuk data validasi. Posisi tubuh pada dataset orang memakai helm proyek dan dataset orang tidak memakai helm proyek bervariasi.

TABEL II
DATASET


	Orang Memakai Helm Proyek	Orang Tidak memakai Helm Proyek	Total
Dataset Training	1200	1200	2400
Dataset Validasi	300	300	600
			3000

- Citra Orang Memakai Helm Proyek



Gambar.11. Citra Orang Memakai Helm Proyek

- Citra Orang Tidak Memakai Helm Proyek



Gambar.12. Citra Orang Tidak Memakai Helm Proyek

B. Pengujian

Uji coba dilakukan pada data uji sejumlah 90 citra yang dibagi menjadi 9 skenario yaitu 1 orang memakai helm proyek, 1 orang tidak memakai helm proyek, 1 orang memakai helm proyek 1 orang memakai topi baseball, 1 orang memakai helm proyek 1 orang tidak memakai helm proyek, 1 orang memakai helm proyek 1 orang memakai helm halfface, 2 orang memakai helm proyek 1 orang memakai topi baseball 1 orang memakai helm halfface 1 orang tidak memakai helm proyek, 2 orang memakai helm proyek ditentang, 3 orang memakai helm proyek dan 3 orang memakai helm proyek 2 orang tidak memakai helm proyek.

Jarak objek dengan kamera adalah 1 – 10 meter. Citra diambil dengan kamera yang diletakkan didepan pekerja yang berjalan kedepan, posisi kamera dipojok dengan ketinggian 2,5 meter diatas tanah. *Threshold* objek adalah 0,3 dan *threshold IOU* adalah 0,3.

Pada Gambar 13 untuk uji coba dengan kondisi 1 orang memakai helm proyek pada jarak objek dengan kamera 4

meter, sistem berhasil mendeteksi dengan benar, nilai prediksi yang dihasilkan adalah 0,789. Sedangkan pada Gambar 14 terdapat 2 objek dengan 2 kelas yang berbeda, yaitu 1 orang memakai helm proyek dan 1 orang tidak memakai helm proyek pada jarak objek dengan kamera 1 meter. Pada kondisi ini objek lebih sulit untuk dideteksi dibandingkan dengan kondisi pada Gambar 13 yang hanya memiliki 1 objek pada sebuah citra. Pada hasil uji coba ini sistem berhasil mendeteksi dengan benar, nilai prediksi yang dihasilkan adalah 0,741 (orang memakai helm proyek) dan 0,376 (orang tidak memakai helm proyek).



Gambar.13. Hasil Uji Coba 1 Orang Memakai Helm Proyek



Gambar.14. Hasil Uji Coba 1 Orang Memakai Helm Proyek 1 Orang

Untuk keseluruhan hasil uji coba ditunjukkan pada Tabel III. Dalam 9 skenario yang telah dijelaskan sebelumnya, pekerja dikondisikan dengan berbagai macam situasi, seperti jumlah pekerja paling sedikit adalah 1 orang dan paling banyak adalah 5 orang. Selain itu penutup kepala tidak hanya helm proyek, tapi digunakan juga topi baseball dan helm *halfface*, hal ini bertujuan untuk menguji sistem dalam mendeteksi penutup kepala selain helm proyek.

TABEL III
DATA HASIL PENGUJIAN

Jarak Objek Dengan Kamera (m)	Kondisi	Precision	Recall	F1-Score
1-10	1 orang memakai helm proyek	1	1	1
1-10	1 orang tidak memakai helm proyek	0,90	0,90	0,90
1-10	1 orang memakai helm proyek 1 orang memakai topi baseball	0,50	0,90	0,63
1-10	1 orang memakai helm proyek 1 tidak memakai helm proyek	0,65	0,90	0,70
1-10	1 orang memakai helm proyek 1 tidak memakai helm halfface	0,90	0,87	0,88
1-10	2 orang memakai helm proyek 1 memakai topi baseball 1 memakai helm halfface 1 tidak memakai helm proyek	0,82	0,57	0,65
1-10	2 orang helm ditengah	0,80	0,80	0,80
1-10	3 orang pakai helm proyek	1	0,87	0,92
1-10	3 orang memakai helm proyek 2 tidak memakai helm proyek	0,80	0,55	0,63
	Rata-rata	0,82	0,82	0,79

V. KESIMPULAN

Dari hasil pengujian pada Tabel III terhadap 90 citra yang dibagi menjadi 9 skenario yang dilakukan diperoleh *F1-score* sebesar 0,79. Hasil *F1-score* untuk jumlah pekerja yang berkelompok (lebih dari 1 orang pekerja) lebih rendah dibandingkan dengan jumlah pekerja yang individu karena seringkali tubuh pekerja berdempetan, tertutup satu dengan yang lain, sehingga sistem kesulitan untuk mendeteksi dengan benar. Dengan hasil ini sistem dapat membantu pengawas untuk memastikan para pekerja menggunakan helm proyek di lokasi pekerjaan dengan hasil yang optimal pada pekerja individu (tidak berkelompok).

DAFTAR PUSTAKA

- [1] J. Mistry, A. K. Misraa, M. Agarwal, A. Vyas, V. M. Chudasama, and K. P. Upla, "An automatic detection of helmeted and non-helmeted motorcyclist with license plate extraction using convolutional neural network," in *2017 seventh international conference on image processing theory, tools and applications (IPTA)*, 2017, pp. 1–6.
- [2] J. Redmon and A. Farhadi, "YOLO9000: better, faster, stronger," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 7263–7271.
- [3] T.-Y. Lin *et al.*, "Microsoft coco: Common objects in context," in

- European conference on computer vision*, 2014, pp. 740–755.
- [4] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” *Commun. ACM*, vol. 60, no. 6, pp. 84–90, 2017.
- [5] X. Chen, P. Wei, W. Ke, Q. Ye, and J. Jiao, “Pedestrian detection with deep convolutional neural network,” in *Asian Conference on Computer Vision*, 2014, pp. 354–365.
- [6] N. Dalal and B. Triggs, “Histograms of oriented gradients for human detection,” in *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR ’05)*, 2005, vol. 1, pp. 886–893.
- [7] S. Sugianto, E. Setyati, and H. Armanto, “Deteksi Alat Pelindung Kepala (Helm) Menggunakan Metode Haar Cascade Classifier,” *Joutica*, vol. 4, no. 1, pp. 232–236, 2019.
- [8] A. Hermawan, “Jaringan Saraf Tiruan: Teori dan Aplikasi,” 2006.
- [9] S. Albawi, T. A. Mohammed, and S. Al-Zawi, “Understanding of a convolutional neural network,” in *2017 International Conference on Engineering and Technology (ICET)*, 2017, pp. 1–6.
- [10] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 779–788.
- [11] M. Menegaz, “Understanding YOLO,” 2017. <https://hackernoon.com/understanding-yolo-f5a74bbc7967>.
- [12] A. Rosebrock, “Intersection over Union (IoU) for object detection,” *l[\i]nea*. [Consultado 20 enero 2020]. Dispon. en <https://www.pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>, 2016.
- [13] A. Kamal, “Yolo, yolov2 and yolov3: All you want to know,” *Mediu. Seach date*, 2019.
- [14] K. Sambasivarao, “Non-maximum suppression (nms),” *Online unter https://towardsdatascience.com/non-maximum-suppression-nms-93ce178e177c [Stand 16.10. 2019]*, 2019.
- [15] M. Septian and K. Kunci, “DETEKSI WAJAH MENGGUNAKAN METODE VIOLA JONES PADA GRAPHICS PROCESSING UNIT FACE DETECTION USING VIOLA JONES METHOD ON GRAPHICS,” *Ilmu Komputer, Tek. Inf.*, 2014.
- [16] V. Yadav, “Generating Anchor boxes for Yolo-like network for vehicle detection using KITTI dataset,” 2017. <https://vivek-yadav.medium.com/part-1-generating-anchor-boxes-for-yolo-like-network-for-vehicle-detection-using-kitti-dataset-b2fe033e5807>.

Pengukuran Material Pada Bak Truk Berbasis Citra

Reddy A. Harianto, *Teknik Informatika Institut Sains dan Teknologi Terpadu Surabaya (ISTTS)*

Abstrak— Proses pengukuran Material bak Truk membutuhkan waktu yang lama jika dilakukan dengan manual. Pengukuran Material Pada Bak Truk Berbasis Citra adalah sebuah terobosan untuk mengukur volume material secara otomatis menggunakan stereo image dengan durasi yang cepat. ZED Stereo Camera digunakan untuk scanning bak truk dan NVIDIA Jetson TX 1 digunakan menghitung muatannya. Pada tahap scanning dilakukan berbagai proses pengolahan citra seperti grayscale, blurring, thresholding, otsu, morphology operation dengan tujuan mengambil nilai depth bak truk dan mencari jarak maksimum serta minimum pada depth bak truk. Proses scanning dilakukan 2 kali yaitu pada saat truck kosong dan truk yang terdapat muatan. Setelah kedua data scanning terpenuhi dilakukan tahap perhitungan material dengan mengolah depth value, sebelumnya depth value dilakukan normalisasi terlebih dahulu. Setelah nilai depth didapatkan dilakukan rumus perhitungan volume pada bak yang berisi, dan juga di lakukan perhitungan volume bak kosong. Selisih dari nilai bak kosong di bandingkan dengan nilai bak isi inilah yang disebut sebagai volume muatan bak truk. Uji coba dilakukan pada jam 07.00-17.30 dengan truk yang berbeda. Terdapat 147 data percobaan terdapat 31 data yang tidak dapat ditemukan nilai depth value nya di karenakan pencahayaan yang kurang baik pada proses scanning. Dari scanning yang berhasil diprediksi nilai volume nya dan dibandingkan dengan nilai volume dengan metode perhitungan manual RMSE perhitungannya pada angka 0.814.

Kata Kunci— *Depth, Muatan Kosong, Muatan Material, Pengukuran Material.*

I. PENDAHULUAN

Pada bidang kontraktor untuk mengetahui volume atau massa material dengan cara manual yaitu harus meratakan material terlebih dahulu dan menghitung volume material dengan menggunakan meteran untuk mengukur panjang bak truk, lebar bak truk, dan tinggi material. Kelemahan cara ini yaitu pengukuran membutuhkan tenaga yang sangat banyak dan juga membutuhkan waktu yang lama [1].

Jembatan timbang sudah banyak [2], [3] digunakan untuk mengatasi masalah pengukuran volume material dengan cara manual. Cara kerja jembatan timbang yaitu menimbang massa truk muatan dikurangi dengan massa truk muatan kosong. Kelemahan dari jembatan timbang adanya kecurangan dengan cara mengatur load cell, Ketika terjadi hujan akan mengalami kerugian pada pihak pembeli karena material menjadi basah, sehingga massa yang terdeteksi jembatan timbang adalah massa material yang basah.

Kendala lain adalah tidak semua pembeli memiliki jembatan timbang karena biaya yang sangat mahal, sehingga mereka biasanya menggunakan jembatan timbang supplier yang rentan untuk dicurangi agar tagihan membengkak. Pada 2016 Pemerintah pusat mengambil alih jembatan timbang dari pemda karena sulitnya mengontrol proses nya dan maraknya kecurangan yang terjadi [4].

Kebiasaan melakukan kecurangan dapat memberikan dampak negatif seperti operator atau pengawas lapangan dapat disuap oleh supplier untuk melakukan kecurangan yang dapat merugikan kepada pihak pembeli itu sendiri. Hal curang tersebut dilakukan agar supplier mendapatkan keuntungan dari kelebihan muatan material yang tidak seharusnya

Kecurangan harus diminimalkan secara maksimal dengan memberikan sistem yang dapat mengawasi semua kegiatan pengukuran, mendigitalkan proses pengukuran dan membuat sistem yang terdapat akses berjenjang. Solusi untuk mengatasi masalah kecurangan yang sering terjadi adalah membuat sistem yang dapat mengukur material pada bak truk dengan gabungan sensor-sensor kamera. Kamera yang digunakan tidak dapat menggunakan kamera biasa, melainkan dengan menggunakan kamera yang memiliki depth sensor untuk mendapatkan kedalaman material pada bak truk. Perbandingan kedalaman antara bak isi dan bak kosong digunakan untuk menghitung volume truk. Tujuan penelitian ini adalah membuat sebuah sistem yang mampu menghitung volume bak truk dari stereo image dan membuat software mendigitalkan pengukuran bak truk yang memiliki batasan-batasan akses proses pengukuran. Selain itu dengan metode penelitian ini proses pengukuran dapat lebih cepat dan biaya peralatan untuk mengukur lebih murah

II. TEORI DASAR

Teori Dasar menjelaskan teori-teori yang mendasari sistem pengukuran material pada bak truk. Terdapat 8 bagian teori-teori dasar yaitu ZED Stereo Camera, NVIDIA Jetson TX 1, Thesholding Otsu, Erosi, Canny Edge Detection, Region of Interest, dan Perspective Transform.

A. ZED Stereo Camera



Gambar. 1. ZED Stereo Camera

Pada Gambar 1 adalah ZED Stereo Camera yang merupakan kamera stereo pasif yang mereproduksi cara

penglihatan manusia bekerja dengan menggunakan dua lensa dan melalui triangulasi serta memahami sekitarnya dan membuat model tiga dimensi dari objek yang diobservasi.

B. NVIDIA Jetson TX1 Developer Kit



Gambar. 2. Jetson TX 1 Developer kit

Pada Gambar 2 adalah Jetson TX1 Developer Kit sebagai platform yang memiliki fitur lengkap untuk melakukan visual computing dengan cepat. Operasi sistem yang kompatibel adalah Linux karena sudah mendukung banyak APIs dan didukung oleh NVIDIA. Board memiliki hardware seperti AC adapter dengan power cord, USB micro B ke USB A adapter, dan dua antena wi-fi. Dengan hardware-hardware tersebut, dapat melakukan komputasi dengan kinerja maksimal. Jetson TX1 Developer Kit memiliki hardware yang paling penting yaitu NVIDIA Jetson TX1 pada Gambar 3 adalah modul supercomputer yang berukuran kecil untuk melakukan visual computing dengan kinerja yang tinggi. Spesifikasinya terbuat dari revolusi arsitektur NVIDIA Maxweel™ dengan 256 NVIDIA CUDA cores untuk mengirim melalui kinerja 1 TeraFlops, 64-bit CPUs, 4K video encode dan decode, dan interface kamera dengan kemampuan 1400 MPix/s yang dapat digunakan untuk deep learning, computer vision, GPU, dan grafik sebagai embedded visual computing.




Gambar. 3. NVIDIA Jetson TX 1

C. Thresholding Otsu

Thresholding Otsu adalah metode untuk mensegmentasi citra digital dan melakukan penyeleksian nilai threshold dari histogram-histogram citra abu-abu. Metode penyeleksian nilai threshold dilakukan dengan memakai pendekatan statistika.

Pada Gambar 4 dapat dilihat gambar proses citra yang mengalami Thresholding Otsu.



Gambar. 4. Thresholding Otsu

D. Erosi


Erosi merupakan teknik lain Morphological Image Processing[5] yang digunakan untuk mengolah bentuk dan struktur dari suatu objek dengan melakukan proses penghapusan titik-titik objek menjadi bagian dari latar berdasarkan structuring element yang digunakan. Proses ini akan membuat ukuran sebuah citra menjadi lebih kecil. Erosi dilakukan dengan memindahkan piksel pada batasan-batasan objek yang akan dilakukan proses Erosi. Jumlah dari piksel yang ditambah atau dihilangkan bergantung pada ukuran dan bentuk dari structuring element yang digunakan untuk memproses citra tersebut. Pada Gambar 5 adalah proses dari citra asli menjadi citra setelah mengalami erosi



Gambar. 5. Contoh Hasil Dilasi dan erosi

E. Canny Edge Detection

Canny Edge Detection[6] merupakan salah satu teknik edge detection yang cukup sering digunakan dalam pengolahan citra karena ketebalan edge yang bernilai satu piksel dimaksudkan untuk melokalisasi posisi edge pada citra secara sepresisi mungkin. Pada Gambar 6 adalah gambar proses citra asli menjadi citra setelah mengalami proses Canny Edge Detection.



Gambar. 6. Canny Edge Detection


F. Region of Interest

Region of Interest adalah suatu bagian dari citra yang dipilih untuk kemudian diproses. Daerah tersebut dibedakan dengan menggunakan klasifikasi dan masking. Jika piksel pada mask tidak nol, maka pemrosesan citra dilakukan. Sebaliknya jika piksel pada mask sama dengan nol, proses tidak dijalankan.

Setelah daerah yang diinginkan ditemukan, daerah tersebut ditandai dengan kotak untuk membatasi daerah yang akan dikenali. Proses Region of Interest (ROI) berbeda dengan block processing yang mana memilih bagiancitra yang akan diambil untuk diproses. Bagian dari citra dalam block processing merupakan bagian citra utuh yang digunakan dalam pengolahan citra.

Dalam Region of Interest, citra dapat didefinisikan lebih dari satu region (bagian). Bagian tersebut dapat berbentuk poligon yang berupa piksel yang contiguous atau berupa range dari intensitas. Dengan kata lain, piksel tidak harus selalu contiguous. Region of Interest sangat membantu untuk segmentasi dalam pemrosesan citra

karena dengan menggunakan teknik ini citra atau obyek dapat lebih mudah dikenali. Pada Gambar 7 adalah proses region of interest untuk mendapatkan region of interest segitiga, segilima, bintang, segi delapan, lingkaran, dan persegi panjang dari sebuah citra.



Gambar. 7. Region of Interest

G. Perspective Transform

Teknik ini memungkinkan untuk merubah bentuk citra asli mengikuti bentuk citra yang dibentuk sebelumnya, sehingga bentuk citra yang akan didapatkan akan cenderung sama. 4 buah titik potong akan digunakan sebagai referensi dalam Perspective Transformation [7]. Setelah 4 buah titik awal didapatkan, selanjutnya menentukan 4 titik tujuan yang akan dijadikan sebagai citra baru. Pada Gambar 8 adalah proses citra asli menjadi citra setelah mengalami proses Perspective Transformation.



Gambar. 1. ZED Stereo Camera

Semua filter-filter image processing yang digunakan pada penelitian ini telah di dukung oleh library opencv [8], pada penelitian ini juga digunakan opencv untuk image processing nya.

H. Pengukuran Bak Truk

Penelitian terkait dengan dump truck tidak hanya menggunakan kamera saja dalam proses penghitungan berat terdapat penelitian lain yang memodifikasi truck dengan pendekatan magnetic [9], [10], dengan memanfaatkan center gravity dari truk [11] dan juga gabungan fuzzy logic dan Neural Network dalam estimasi berat truck [12].

Selain itu untuk menghindari kecurangan terdapat sistem yang menambahkan suatu device wireless [13] pada truck seperti rfid yang harus di scan pada sistem, wireless tersebut membawa informasi data terkait dengan muatan dan data barang, Sistem ini digunakan karena banyak yang melakukan kecurangan dengan mengubah dokumen. Jika dengan wireless device ini maka akan lebih sulit melakukan kecurangan pada berat barang.

III. DESAIN SISTEM

Penjelasan mengenai sistem ini melingkupi desain kerangka, desain kamera, desain konektivitas, prosedur operasi standar, arsitektur sistem, fitur, dan desain algoritma. Selain penjelasan mengenai kronologis sistem, juga akan diberikan gambaran mengapa sistem tersebut

tidak jadi digunakan dalam penelitian ini beserta solusi yang diterapkan dijumpai pada saat melakukan penelitian.

A. Desain Kerangka.

Desain kerangka terinspirasi dari desain kerangka load scanner yang memiliki desain portable, tiang back stays, kokoh, memiliki tempat penyimpanan, dan meja kerja seperti prototipe pada Gambar 9. Setelah itu, dapat dikonsultasikan kepada tukang las dan kemudian dibuatlah desain kerangka yang nyata. Desain ini memiliki kelebihan diantaranya yaitu:

1) Portable

Desain portable memiliki konsep sama seperti gerobak. Ketika kerangka sudah dipindah ke tempat yang dituju, kerangka dapat dikunci dengan 4 kaki yang fleksibel sebagai penopang agar tidak berpindah-pindah.

2) Tiang Kerangka

Tiang kerangka memiliki konsep seperti antena yang dapat ditarik. Cara untuk menaikkan dengan cara memasukkan baut-baut besi untuk menahan tiang-tiang berikutnya saat dinaikkan dan cara menurunkannya dengan cara menarik baut-baut besi yang sedang menahan tiang-tiang yang sedang terpasang.

Tinggi tiang menjadi kunci utama dalam pengukuran material. Pencarian ketinggian yang tepat dilakukan dengan memahami berbagai ukuran-ukuran truk dari yang kecil sampai besar. Desain alat ini nantinya akan digunakan oleh jenis truk yang kecil sampai besar. Terdapat tiga hal sebagai penentu ketinggian tiang back stays yaitu ketinggian truk, jarak minimum kamera, dan jarak tak terduga.



Gambar. 9. Prototipe Desain Kerangka


3) Ketinggian Truk

Patokan yang digunakan untuk ketinggian truk adalah truk besar. Truk besar seperti pada Gambar 10 memiliki tinggi 3,37 meter serta panjang 8,985 meter dengan tinggi bak truk 1,7 meter, tetapi spesifikasi setiap truk berbeda-beda. Perbedaan yang paling mencolok adalah pada ketinggian bak truk, sehingga disimpulkan ketinggian truk paling tinggi adalah 4 meter.

4) Jarak Minimum Kamera

Kamera dapat mengukur depth dengan ketentuan minimum jaraknya adalah 1 meter. Jika objek memiliki jarak dibawah 1 meter, ada kemungkinan objek tidak

teridentifikasi karena dianggap terlalu dengan kamera.



Gambar. 10. Spesifikasi Dump Truck Besar

5) Jarak Tak Terduga

Jarak tak terduga juga diperlukan untuk mengantisipasi panjangnya truk besar yang sangat panjang, sehingga perlu diberikan jarak 1 meter lagi. Ketinggian tiang back stays dijumlahkan dari ketinggian truk paling tinggi (4 meter), minimum jarak kamera dengan objek (1 meter), dan jarak takterduga (1 meter) yang totalnya menjadi 6 meter.

6) Kokoh

Desain kerangka ini cukup tinggi sampai mencapai 6 meter. Oleh karena itu, diperlukan kekokohan kerangka agar tidak mudah tumbang tertiuip oleh angin. Bahan yang digunakan untuk membuat kerangka adalah besi dan plat besi.

7) Tempat Penyimpanan

Tempat penyimpanan terletak pada tengah-tengah gerobak kerangka yang ditutup oleh plat besi. Ukuran tempat penyimpanan memiliki panjang 1 meter dan lebar 0,5 meter. Terdapat tempat untuk mengunci tempat penyimpanan menggunakan gembok agar lebih aman dan tidak dicuri.

8) Meja Kerja

Tutup dari tempat penyimpanan yang terbuat dari plat besi bisa digunakan sebagai meja kerja untuk operator. Ukuran meja kerja memiliki panjang 1 meter dan 0,5 meter.

Pada proses pembangunan kerangka, tentunya dibutuhkan desain untuk dapat membangun kerangka agar dapat menjalankan pengukuran material yang diperlukan. Kerangka yang dibuat dalam penelitian ini menggunakan bahan besi agar kokoh. Gambar 11 di bawah ini menunjukkan kerangka dengan spesifikasinya yang digunakan untuk pengukuran material.

Desain akhir bentuk kerangka dalam penelitian ini mengalami serangkaian percobaan dan pergantian bentuk sebelum sampai kepada desain kerangka tahap akhir ini. Meskipun desain kerangka ini merupakan desain akhir pada penelitian ini, tidak menutup kemungkinan kerangka ini masih dapat dikembangkan ke desain yang lebih baik lagi.

1) Pengaturan Depth

Konfigurasi kamera diperlukan agar pengukuran material dapat dilakukan dengan baik. Hal yang harus diatur adalah pengaturan video, depth, dan adaptasi cahaya. Kualitas gambar saat pengambilan dapat ditentukan melalui pengaturan video. Sedangkan, pengaturan gambar depth dapat ditentukan konfigurasinya sesuai dengan keperluan.



Gambar. 11. Spesifikasi Kerangka

2) Pengaturan Video


Mode Video terdiri dari resolusi, frame rate per second, dan sudut kamera seperti pada Tabel 1. Mode Video hanyalah nama lain dari ukuran resolusi tersebut. Dalam pengukuran material ini, mode video yang digunakan adalah 720p seperti pada Gambar 12 (c) atau dengan resolusi 2560x720 piksel karena memiliki sudut kamera terlebar kedua dengan kualitas resolusi yang bagus. Kualitas mode WVGA memang terlebar pertama, tetapi foto yang diambil terlalu kecil resolusinya. Frame rate yang digunakan adalah 60 fps agar gambar yang diproses setiap detiknya menjadi lebih maksimal mengikuti keadaan nyata.

TABEL I
TABEL MODE ZED STEREO CAMERA

Mode Video	Resolusi	Frame Rate per Second	Sudut Kamera
2.2K	4416x1242	15	Wide
1080p	3840x1080	30, 15	Wide
720p	2560x720	60, 30, 15	Extra Wide
WVGA	1344x376	100, 60, 30, 15	ExtraWide

3) Pengaturan Depth

Terdapat 3 hal konfigurasi depth yang diperlukan yaitu konfigurasi pada mode depth, satuan, dan sensing. 3 hal ini memiliki peran masing-masing untuk membantu dalam pengukuran material. Mode depth dapat membantu untuk mendeteksi bagian truk saja dengan sensing mode yang memiliki jenis keakurasian depth untuk mengukur dalam satuan yang diperlukan.




Gambar . 12. Hasil Foto Kamera ZED Stereo Camera

• Mode Depth

Beberapa mode depth tersedia untuk meningkatkan kinerja sesuai dengan pengaplikasiannya. Terdapat 4 jenis mode depth yaitu ultra, quality, medium, dan performance. setiap mode ini menyesuaikan tingkat akurasi, jangkauan dan kinerja komputasi dari modul penginderaan kedalaman.

Mode ultra memberikan rentang kedalaman tertinggi dan lebih baik mempertahankan akurasi Z seperti Gambar 13 (a), mode quality menawarkan kompromi antara kualitas dan kecepatan serta masih mengutamakan kualitas seperti pada Gambar 13 (b), mode medium menawarkan kompromi antara kualitas dan kecepatan serta masih mengutamakan kecepatan seperti pada Gambar 13 (c), mode performance menonaktifkan beberapa pemfilteran dan operasi pada resolusi yang lebih rendah untuk meningkatkan kinerja dan frame rate seperti pada Gambar 13 (d).



Gambar . 13. Hasil Foto Kamera ZED Stereo Camera

• Satuan


Satuan ini berpengaruh pada data point cloud yang akan diambil oleh kamera. Standar satuan yang digunakan kamera adalah millimeter. Perubahan satuan dapat dilakukan ke satuan meter, centimeter, kaki, dan inci.

• Mode Sensing

Terdapat 2 jenis mode sensing yaitu mode Standard dan


Fill. Mode standard dan fill memiliki hasil perbedaan gambar depth yang diambil oleh kamera. Penggunaan mode ini dapat ditentukan sesuai dengan keperluan untuk pengolahan citra yang diinginkan.

Mode Standard adalah mode pendeteksi kedalaman default pada kamera. Mode Standard mempertahankan metrik serta bentuk jarak dan berjalan lebih cepat daripada mode fill, tetapi berisi lubang karena oklusi visual dan penyiangan. Lubang-lubang ini diwakili oleh area hitam di kedalaman gambar. Pada Gambar 14 adalah contoh foto dengan mode depth Standard.



Gambar . 14. Foto dengan Mode Depth Standard

Mode fill memberikan kepadatan depth dengan nilai z untuk setiap piksel (x, y) di gambar kiri. Mode fill mengisi lubang dan oklusi di peta kedalaman dan menambahkan tahap penyiangan yang memperbaiki tepi dan stabilitas sementara, tetapi dapat mengubah jarak objek yang sebenarnya. Mode ini membutuhkan lebih banyak resource dan akan berjalan pada fps yang lebih rendah daripada mode standard. Pada Gambar 15 adalah contoh foto dengan mode depth fill.



Gambar . 15. Foto dengan Mode Depth Fill

Dalam pengukuran material, jenis mode depth yang digunakan adalah mode fill. Alasan menggunakan mode depth fill karena objek tidak memiliki lubang yang nantinya akan memberikan hasil thresholding otsu yang baik untuk mencari region of interest.


• Pengaturan Adaptasi Cahaya

Pengaturan adaptasi cahaya pada kamera sangat diperlukan sama seperti mata manusia yang perlu adaptasi setelah bangun tidur. Kamera membutuhkan waktu untuk beradaptasi menstabilkan cahaya yang masuk. Waktu yang diperlukan untuk adaptasi adalah 3,75 detik. Pada Gambar 16 adalah perbedaan tidak menggunakan adaptasi dan adaptasi 3,75 detik.



Gambar . 16. Perbedaan Tidak Menggunakan Adaptasi dan Adaptasi 3,75 Detik

B. Arsitektur Sistem



Gambar . 17. Foto dengan Mode Depth Standard

Arsitektur sistem sistem seperti pada Gambar 17 dapat terjadi dengan kerjasama yang baik dari setiap peran yang diperlukan. Semua data akan berpusat pada server sebagai tempat penyimpanannya. Terdapat 4 peran yang diperlukan dalam alur kerja yaitu peran operator, pengawas lapangan, manajer, dan staf. Setiap peran memiliki tanggung jawab masing-masing sesuai dengan jabatan pekerjaannya. Operator memiliki peranan besar di dalamnya serta dibantu diawasi oleh pengawas lapangan dan manajer memiliki peran dalam menjaga sekuritas data untuk memahami setiap kejadian masalah.

1) Operator

Operator adalah pengguna yang mengoperasikan pengukuran material pada bak truk. Peran operator yaitu memastikan truk harus berhenti di scan area dan melepas tutup terpal agar pengukuran mampu menjangkau material pada bak truk. Setelah itu, meminta surat jalan dan menginputkan data-data seperti satuan yang digunakan (m3 atau ton), nomor polisi, nama, jenis material, tujuan pengiriman (hanya untuk kegiatan penjualan), dan menanyakan validasi data yang diinputkan secara lisan kepada sopir truk agar tidak terjadi kesalahan data. Jika terdapat keperluan untuk mengukur material menggunakan satuan ton, maka operator harus menginputkan massa jenis material yang diberikan oleh pengawas lapangan. Langkah berikutnya adalah operator memproses pengukuran material yang hasilnya akan dicetak pada printer.

Jika terjadi keperluan untuk update, delete, dan menandai data, operator memerlukan token untuk melakukan hal tersebut. Token dapat diperoleh dari manajer. Operator harus menginputkan keterangan alasan melakukan update atau hapus data tersebut.

2) Pengawas Lapangan

Pengawas Lapangan akan memberikan massa jenis material jika terdapat keperluan untuk mengukur material menggunakan satuan ton. Massa jenis material dapat diperoleh dari hasil lab material proyek tersebut atau nilai sudah diberikan oleh pihak pembeli. Jika nilai massa jenis material dari pembeli, harus diselidiki dulu keakuratan nilai tersebut serta harus dapat dipertanggungjawabkan oleh pengawas lapangan.

Peran penting lainnya dari pengawas lapangan adalah memantau semua surat jalan hasil pengukuran material. Jika terjadi kesalahan data pada surat jalan hasil pengukuran material, maka pengawas lapangan meminta operator untuk update data tersebut dan mencetak surat jalan hasil pengukuran material yang baru.

Pengawas Lapangan dapat memberikan izin untuk tetap melakukan pengukuran jika terdapat masalah teknis pada lapangan seperti tidak membawa surat jalan dan mencurangi muatan. Jika saat kegiatan ditemukan mencurangi muatan, maka pengawas lapangan berhak memotong hasil pengukuran material dan meminta operator untuk menandai curang dan mengurangi nilai pengukuran material.

3) Manajer

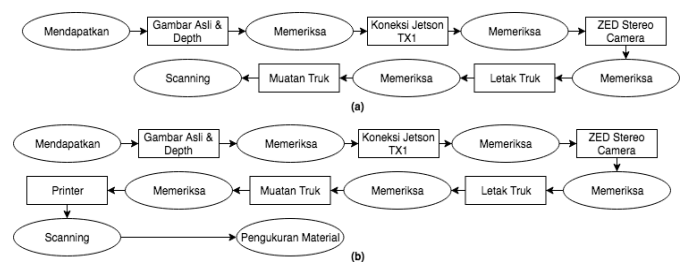
Batasan hak akses pada operator akan dibatasi menggunakan token, sehingga kecurangan yang terjadi akan terminimalkan. Hanya manajer yang dapat mengakses sistem untuk mengambil token. Token tersebut akan diberikan kepada operator untuk keperluan update, delete, dan menandai data. Dengan cara ini, manajer dapat mengetahui kejadian operator melakukan update, delete, dan penandaan data untuk memahami kejadian pada lapangan.

4) Staf

Staf dapat melihat stok pada sistem untuk keperluan koleksi data untuk administrasi kantor.

C. Pengukuran Material Bak


Scan area yang dibuat dalam penelitian ini adalah sebuah sistem yang mampu memvalidasi scan area ketika ingin scanning. Setelah pemeriksaan scan area berhasil, sistem melanjutkan scanning. Terdapat 2 pemeriksaan scan area yaitu pemeriksaan scan area saat scanning pertama seperti pada Gambar 18 (a) dan scanning kedua yang dapat dilihat pada Gambar 18 (b).



Gambar . 18. Arsitektur Sistem Pemeriksaan Scan Area


Pada tahap pemeriksaan scan area untuk scanning pertama, tidak perlu memeriksa printer karena masih belum perlu untuk mencetak report. Sedangkan, pada tahap pemeriksaan scan area untuk scanning kedua, perlu memeriksa printer untuk keperluan mencetak printer. Sistem akan memeriksa muatan apakah sedang bermuatan material atau kosong. Pada tahap pemeriksaan scan area untuk scanning kedua, terdapat pemeriksaan muatan material yang akan dapat memeriksa apakah muatan tersebut berlawanan status muatannya dengan scanning kedua. Ketika scanning pertama bermuatan material, maka scanning kedua harus bermuatan kosong.

Scanning penelitian ini dibuat dengan tujuan untuk mendapatkan depth pada bagian bak yang difotokan oleh ZED Stereo Camera yang dioperasikan oleh NVIDIA Jetson TX 1 yang nantinya akan menghitung muatan material pada truk tersebut. Sistem yang akan dibuat adalah mampu mendeteksi bak sebagai fokusnya tempat material dan menyimpan depth pada bak tersebut yang nantinya akan diolah lagi pada sistem pengukuran material seperti pada Gambar 19.



Gambar . 19. Arsitektur Sistem Scanning

Setelah proses scanning kedua selesai, akan dilanjutkan mendapatkan ujung-ujung pada bak truk untuk memotong citra depth bagian bak truk saja. Sistem yang akan dibuat akan melakukan berbagai tahapan untuk mengolah gambar dan depth agar dapat terfokus pada bagian bak saja seperti pada Gambar 20.



Gambar . 20. Arsitektur Sistem Pengambilan Bak Truk

Awalnya akan dicari minimum dan maksimum kedua scanning bertujuan untuk normalisasi depth. Tahap Dari Normalisasi sampai Transformasi akan dialami pada kedua data scanning yaitu bermuatan material dan kosong.

Hasil dari transformasi citra depth bermuatan material dan kosong akan dilakukan pengukuran material dengan tahapan seperti pada Gambar 21.



Gambar . 21. Arsitektur Sistem Perhitungan Material

Setelah itu, memvisualisasi 3 dimensi hasil pengurangan citra depth serta membuat laporan seperti pada Gambar 22.



Gambar. 22. Arsitektur Sistem Pemvisualisasian Material

A. Fitur

Fitur-Fitur dibuat untuk menunjang tujuan dari pengukuran material pada bak truk dapat tercapai. Pengukuran material pada bak truk membutuhkan kesinambungan antara hardware dan software. Software dapat berjalan dengan baik dengan dukungan hardware yang menunjang.

1) Hardware

Kerangka ini dapat dibongkar pasang dan dipindahkan ke tempat yang diinginkan semudah seperti mendorong gerobak karena didesain dengan memiliki roda. Ketika sudah menemukan area untuk pengukuran, terdapat 4 kaki fleksibel yang dapat diturunkan mencapai dasar sebagai penopang. Tidak seperti jembatan timbang yang membutuhkan area yang luas untuk meletakkan jembatan timbang dan bersifat paten.

- Portable

Kerangka ini dapat dibongkar pasang dan dipindahkan ke tempat yang diinginkan semudah seperti mendorong gerobak karena didesain dengan memiliki roda. Ketika sudah menemukan area untuk pengukuran, terdapat 4 kaki fleksibel yang dapat diturunkan mencapai dasar sebagai penopang. Tidak seperti jembatan timbang yang membutuhkan area yang luas untuk meletakkan jembatan timbang dan bersifat paten.

- Tiang Kerangka yang Fleksibel

Tiang Kerangka ini berguna untuk menaikkan kamera agar dapat menjangkau truk yang hendak diukur dan didesain fleksibel agar bisa diturunkan untuk dimasukkan ke dalam ruangan ketika tidak dipakai. Maksimal ketinggian kerangka adalah 6 meter.

- Kokoh

Terbuat dari besi dan plat besi yang tebal, sehingga memiliki kaki yang kuat menginjak dasar dan tidak mudah goyang terkena angin. Terdapat 4 kaki yang akan menempel pada tanah. Setiap kaki juga bersifat fleksibel untuk menyesuaikan kemiringan pada tempat untuk mengukur. Dengan kekokohan ini, memberikan stabilitas agar device-device tidak terkokok-kocok.

- Tempat Penyimpanan

Fungsi tempat penyimpanan berguna untuk menyimpan semua hardware dan peralatan ketika alat sedang tidak digunakan seperti stop kontak, kabel rol, monitor, keyboard, mouse, printer, kabel-kabel dan keperluan peralatan lainnya. Tempat penyimpanan dapat digembok agar lebih aman dan tidak dicuri.

- Meja Kerja

Operator selalu standby menunggu truk yang datang untuk mengukur material. Oleh karena itu, diperlukan meja kerja untuk meletakkan device-device seperti monitor, keyboard, mouse, printer, dan bisa juga digunakan untuk menulis.

- Integrasi dengan Teknologi

Terdapat NVIDIA Jetson TX1 Developer Kit sebagai komputer untuk mengolah data, ZED Stereo Camera sebagai kamera, router sebagai media komunikasi antar

komputer, server sebagai pusat penyimpanan data, dan satu komputer untuk mengoperasikan. Dengan adanya teknologi tersebut, dapat membantu untuk mengukur material, mengolah data, mengkoneksikan ke server, dan dapat dibuka melalui gadget-gadget lainnya.

2) Software

Fitur-Fitur software dapat berjalan dengan baik dengan dukungan dari desain hardware yang telah dirancang sedemikian rupa. Dengan fitur-fitur pada software ini, dapat membantu pekerjaan agar lebih efisien. Terdapat 7 fitur-fitur software yaitu fitur perhitungan muatan material, konversi satuan, visualisasi, surat hasil pengukuran, token, pencatatan, dan penyimpanan.

- Perhitungan Muatan Material

Truk yang digunakan harus dump truck atau truk dengan kap terbuka. Jenis dump truck juga bervariasi macamnya. Pada umumnya terdapat 3 jenis ukuran dump truck yaitu truk kecil, sedang, dan besar. Perbedaan ukuran berpengaruh pada muatan yang diangkut. Semakin besar jenis dump trucknya, dapat membawa muatan lebih banyak. Bak truk juga memiliki berbagai jenis desain dan pada umumnya desain bak truk dapat dilihat pada Gambar 23 yaitu bak truk berbentuk kotak, tipe u, dan lengkung.



Gambar . 23. Bak Truk Kotak, Tipe U, dan Lengkung

Pada Gambar 24 adalah bak truk yang dimodifikasi agar dapat mengangkut muatan material lebih banyak lagi. Oleh karena itu, diperlukan 2 kali pengukuran material yaitu ketika mengangkut muatan material dan ketika truk bermuatan kosong agar sistem selalu mengetahui kondisi model bak truk tersebut.



Gambar . 24. Bak Truk Kotak, Tipe U, dan Lengkung

Pada Gambar 25 adalah jenis truk yang digunakan untuk mengangkut material yaitu truk kecil dengan ukuran bak truk panjang 3,75 meter, lebar 1,9 meter,

tinggi 1,13 meter yang memiliki kemampuan 8,05 m³. Ukuran bak truk dapat berbeda-beda sedikit meskipun jenis truknya sama, sehinggamenhasilkan kemampuan volume yang berbeda-beda sedikit juga.



Gambar . 25. Truk Kecil

Perhitungan muatan material pada bak truk dilakukan dengan 4 tahap perhitungan yaitu mengambil permukaan baktruk ketika muatan kosong seperti pada Gambar 26 (a) dan mengambil permukaan material pada bak truk ketika bermuatan seperti pada Gambar 26 (b).



(a) (b)

Gambar . 26. Foto Bak Truk Bermuatan Kosong dan Material


Tahap berikutnya adalah tahap penggabungan nilai permukaan material pada bak truk ketika bermuatan dengannilai permukaan bak truk ketika bermuatan kosong. Sebelummelakukan penggabungan, terdapat 5 tahap untuk mengambil nilai bak truknya saja setelah proses scanning yaitumelakukan preprocessing pada foto scanning, melakukanedge detection untuk menemukan bak truk dari tampak atas,mengambil nilai permukaan muatan material pada bak truk,dan nilainya disimpan sementara untuk nantinya akan digabungkan setelah mendapatkan nilai permukaan bak truk ketika bermuatan kosong. Penggabungan ini akan menghasilkan muatan material yang diangkut pada bak truk. Berikutnya akan dilakukan perhitungan material pada bak truk dengan menjumlahkan nilai permukaan muatan kosongdikurangi dengan nilai permukaan muatan material pada bak truk

- Konversi Satuan

Hasil pengukuran material berupa volume dan terkadang dibutuhkan satuan ton sesuai dengan permintaan. Oleh karena itu, diperlukan konversi satuan m³ ke kilogram dengan mengalikan volume dengan massa jenis material dan dibagi dengan 1000 untuk mengubah satuan menjadi ton.

- Visualisasi

Saat kamera mengambil Gambar truk hanya terlihat tampak atas saja, sehingga menyusahkan untuk melihat munjung atau peresnya material tersebut. Oleh karena itu, hasil pengukuran volume material dapat divisualisasikan menjadi 3 dimensi agar dapat terlihat dari berbagai sudut seperti pada Gambar 27.



Gambar. 27. Truk Kecil

• Surat Hasil Pengukuran

Surat Hasil Pengukuran adalah laporan dari hasil pengukuran yang telah dilakukan. Terdapat berbagai informasi-informasi pada surat hasil pengukuran yaitu profil perusahaan (logo, nama, alamat, telepon dan email), data customer (perusahaan, tujuan, dan nomor polisi), foto hasil scanning (foto truk bermuatan material, foto truk bermuatan kosong, dan foto visualiasi material), dan informasi pengukuran (kode, waktu, material, masalah pengukuran, hasil pengukuran, satuan pengukuran, dan massa jenis material). Surat Hasil Pengukuran juga dapat digunakan sebagai surat jalan untuk megiringi pengangkutan material ketujuan. Pada Gambar 28 adalah contoh surat hasil pengukuran setelah melakukan scanning.



Gambar. 28. Surat Hasil Pengukuran

• Token

Token digunakan sebagai pengaman dan batasan hak akses seperti melakukan update, delete, dan penandaan data. Operator dapat meminta token pada manajer, sehingga setiap masalah yang terjadi pada data dapat dipantau oleh manajer.

• Pencatatan

Setiap aktivitas dalam sistem akan tercatat secara detail agar semua hal yang terjadi pada sistem ini dapat dipantau dengan baik. Pencatatan dapat dilihat oleh semua pengguna karena bersifat transparan, sehingga tidak terjadi korupsi dalam perusahaan.

• Penyimpanan

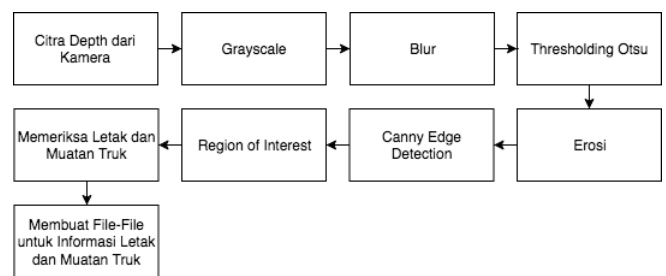
Setiap data pengukuran material akan disimpan pada server agar data dapat diakses oleh semua pengguna yang terdaftar pada sistem, sehingga tidak perlu repot-repot untuk melakukan pencadangan data.

B. Desain Algoritma

Desain algoritma ini akan dijelaskan mengenai algoritma-algoritma yang dipakai untuk menyelesaikan sistem perhitungan material pada bak truk ini. Terdapat tiga algoritma yang dipakai dalam penyelesaian permainan ini, yaitu algoritma untuk scan area, scanning, dan perhitungan material (measurement). Penjelasan susunan langkah inidijelaskan dengan menggunakan bantuan teknik blok diagram. Desain algoritma ini menjelaskan pertama-tama adalah proses secara global dari awal sampai akhir, baru di bab 4 akan menjelaskan lebih detail dan lebih terperinci dengan menggunakan script untuk menuliskan algoritmanya. Berikut ini algoritma yang dipakai dalam penyelesaian:

1) Scan Area


Proses scan area dapat dilihat pada Gambar 29 yang terdiri dari tahapan-tahapan mencari objek truk tersebut dan memastikan truk masuk di dalam garis pembatas.



Gambar. 29. Blok Diagram Scan Area

2) Scanning


Scanning saat truk bermuatan material dan tidak bermuatan harus dilakukan karena perhitungan material akan berdasarkan nilai truk bermuatan material yang nantinya diproses bersamaan dengan nilai truk tidak bermuatan. Prosesnya dapat dilihat pada Gambar 30 yang terdiri dari tahapan-tahapan mencari objek truk tersebut dan mengambil nilai bak truknya saja.



Gambar. 30. Blok Diagram Scanning

3) Perhitungan Material

Perhitungan material (measurement) akan mengakses hasil scanning truk bermuatan material dan tidak bermuatan. Prosesnya adalah menjumlahkan semua hasil pengurangan jarak truk tidak bermuatan dengan truk bermuatan material. Terdapat 10 proses pengolahan citra untuk perhitungan material yang dapat dilihat pada Gambar 31.



Gambar. 31. Blok Diagram Pengukuran Material

IV. UJI COBA

Uji coba ini akan menjelaskan tentang segala sesuatu yang berhubungan dengan uji coba yang dilakukan terhadap program penelitian ini. Penjelasan mengenai hasil uji coba diinformasikan secara detail seperti foto uji coba, waktu uji coba, uji coba deteksi truk, nilai uji coba, serta nilai errornya yang nantinya akan dihitung rata-ratanya untuk mendapatkan tingkat keberhasilannya beserta penjelasan penyebab kegagalan bisa terjadi selama uji coba.

Percobaan dilakukan pada jam 07.00-17.30 dengan truk yang berbeda serta material yang tidak menentu karena percobaan ini tidak boleh mengganggu pekerjaan. Keberhasilan dari uji coba ini akan menampilkan tingkat keberhasilan. Pada tabel 2, 3, dan 4 hanya menampilkan perwakilan 1 uji coba.

TABEL 2
TABEL ID LS 1 MUATAN MATERIAL

Bak	TX1	Manual	Selisih
Atas Kiri	343,148	322,136	21,12
Atas Kanan	982,159	995,143	13,16
Bawah Kiri	339,476	298,478	41,2
Bawah Kanan	977,487	911,495	66,8

TABEL 3
TABEL ID LS 1 MUATAN KOSONG

Bak	TX1	Manual	Selisih
Atas Kiri	142,117	125,117	17,0
Atas Kanan	828,108	868,108	40,0
Bawah Kiri	146,477	129,469	17,8
Bawah Kanan	832,468	810,470	22,2

TABEL 4
TABEL ID LS 1 DIMENSI BAK TRUK

Dimensi Bak Truk	TX1	Manual	Selisih
Panjang	361	375	14
Lebar	197	190	7
Tinggi	118,66	113	5,66
Volume	8,44	8,05	0,38

Terdapat 147 data yang diantaranya terdapat 31 data yang tidak bisa mendeteksi depth value dari bak truk saat discanning. Pada proses ujicoba ini dicatat ID scanning, status muatan, foto scanning, tanggal dan waktu scanning, foto depth bak truk, dimensi depth bak truk (P adalah panjang dan L adalah lebar), koordinat truk yang dideteksi oleh ZED Stereo Camera, koordinat truk yang dideteksi secara manual, dimensi truk (panjang, lebar, dan tinggi) yang dideteksi oleh ZED Stereo Camera, dimensi trukasinya (panjang, lebar, dan tinggi), volume hasil perhitungankomputer, volume nyata pada lapangan, selisih koordinat yang dideteksi oleh ZED dengan cara penandaan manual, selisih dimensi truk (panjang, tinggi, dan lebar), dan selisih volume.

Awal mulanya melakukan pencarian koordinat bak truk yang bermuatan dan tidak bermuatan, yang ditulis pada fieldkoordinat atas kiri, atas kanan, bawah kiri, dan bawah kanan. Setelah itu, diproses pengolahan citra foto depth untuk diambil bagian depth bak truknya saja. Setiap depth loaded dan unloaded memiliki dimensi ukuran panjang depth dan lebar depth berbeda dengan satuan piksel. Oleh karena itu, perlu diambil nilai rata-rata dari ukuran dimensi depthnya yang nantinya setiap foto depth akan diubah dimensi ukurannya sesuai dengan nilai rata-rata panjang depth dan lebar depthnya. Pada nilai panjang truk, akan dikonversi ke cm dengan cara dibagi nilai 1.77 dan nilai lebar truk akan dikonversi ke cm dengan cara dibagi nilai 1.65. Tinggi truk akan didapatkan dengan melakukan akumulasi penjumlahan pada setiap nilai pengurangan piksel unloaded terhadap pengurangan piksel loaded. Setelah selesai dilakukan akumulasi penjumlahan, nilai tersebut akan dibagi dengan 1.3625 untuk menjadi nilai tinggi truk dengan satuan cm. Tiga data truk sudah didapatkan yaitu panjang truk, lebar truk, dan tinggi truk yang nantinya akan dikalikan semuanya menjadi sebuah nilai volume material. Dari semua hasil uji coba tersebut, dilakukan perhitungan selisih pada pendeteksian koordinat bak truk (atas kiri, atas kanan, bawahkiri, dan bawah kanan), dimensi bak truk (panjang, lebar, dan tinggi), dan volume material akan dihitung menggunakan root mean square seperti pada tabel 5 untuk koordinat bak truk dan tabel 6 untuk dimensi bak truk.

TABEL 5
TABEL ROOT MEAN SQUARE KOORDINAT BAK TRUK

Koordinat Bak Truk	RMSE	Koordinat Bak Truk	RMSE
Atas Kiri X	5,78	Bawah Kiri X	5,60
Atas Kiri Y	3,00	Bawah Kiri Y	4,91
Atas Kanan X	6,27	Bawah Kanan X	6,73
Atas Kanan Y	4,38	Bawah Kanan Y	3,70

TABEL 6
TABEL ROOT MEAN SQUARE DIMENSI BAKTRUK

Dimensi Bak Truk	RMSE	Hasil Akhir	RMSE
Panjang	2,91	Volume	0,814
Lebar	3,59		
Tinggi	4,50		

V. KESIMPULAN

Dalam penelitian ini diperoleh sejumlah kesimpulan. Kesimpulan ini didapatkan dari teknik-teknik yang telah dilakukan. Selain itu kesimpulan juga didapatkan dari kegagalan yang terjadi dari proses-proses yang dilakukan. Sehingga kesimpulan ini dijabarkan sebagai berikut:

- 1) Metode perhitungan bak truk dapat masih harus di tingkatkan akurasi nya, sistem yang dibuat belum bisa menggantikan perhitungan yang sudah ada saat ini. RMSE perkiraan volume dari 147 percobaan yang adalah 0.814.
- 2) ZED Stereo Camera memberikan data depth kurang akurat, sehingga hasil yang diberikan kurang stabil
- 3) Pencahayaan sangat mempengaruhi hasil pengukuran material. Oleh karena itu, diperlukan pencahayaan yang stabil, hal ini juga mempengaruhi waktu pengambilan data.
- 4) Hasil keakurasian kurang tepat, sehingga akan mengalami banyak kerugian.

DAFTAR PUSTAKA

[1] P. Patyk Michał and Bodziony and Z. Kasztelewicz, “Analysis of quarrying equipment operating cost structure,” *Inżynieria Miner.*, vol. 21, 2019.

[2] Tazkiyah, “JEMBATAN TIMBANG DAN EFEKTIFITAS PENYELENGGARAANNYA,” 2021. .

[3] M. V Vasiliev, “Transport processes and equipment in quarries [Transportnie protsessy i oborudovanie na kar’erakh].” Moscow, Nedra publ, 1986.

[4] A. M. Daryono, “Pemerintah akan Ambil Alih 140 Jembatan Timbang dari Pemda,” 2016. <https://mediaindonesia.com/ekonomi/73933/pemerintah-akan-ambil-alih-140-jembatan-timbang-dari-pemda> (accessed Jan. 14, 2022).

[5] S. Chen and R. M. Haralick, “Recursive erosion, dilation, opening, and closing transforms,” *IEEE Trans. image Process.*, vol. 4, no. 3, pp. 335–345, 1995.

[6] J. Canny, “A computational approach to edge detection,” *IEEE Trans. Pattern Anal. Mach. Intell.*, no. 6, pp. 679–698, 1986.

[7] I. Her, “Geometric transformations on the hexagonal grid,” *IEEE Trans. Image Process.*, vol. 4, no. 9, pp. 1213–1222, 1995.

[8] OpenCV, “OpenCV Modules,” 2019. .

[9] A. Nikishechkin, L. Dubrovin, and V. Davidenko, “Estimating Cargo Weight of Dump Truck,” in *2020 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon)*, 2020, pp. 1–4.

[10] M. A. Semenov, O. M. Bolshunova, A. A. Korzhev, and A. M. Kamyshyan, “Modernization of dump truck onboard system,” in *IOP Conference Series: Earth and Environmental Science*, 2017, vol. 87, no. 2, p. 22017.

[11] Y. Mikata, M. Yamanaka, K. Kameoka, A. Okunosono, and T. Kinoshita, “Measuring the center of gravity with truck scale,” in *SICE Annual Conference 2011*, 2011, pp. 405–410.

[12] H. Lin, Y. Lin, J. Yu, Z. Teng, and L. Wang, “Weighing Fusion Method for Truck Scales Based on Prior Knowledge and Neural Network Ensembles,” *IEEE Trans. Instrum. Meas.*, vol. 63, no. 2, pp. 250–259, 2014, doi: 10.1109/TIM.2013.2278577.

[13] Z. Yanjun, Q. Bin, G. Ruikun, and P. Yifei, “Anti-cheating monitoring system of the electronic truck scale,” in *2010 International Conference on Intelligent Computation Technology*

Stance Classification Pada Berita Berbahasa Indonesia Berbasis Bidirectional LSTM

Esther Irawati Setiawan, *Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya*
Ika Lestari, *Magister Teknologi Informasi Institut Sains dan Teknologi Terpadu Surabaya,*

Abstrak—Berita palsu masih menjadi masalah yang harus mendapat perhatian khusus. Media sosial, termasuk Facebook menjadi salah satu sarana yang mudah dan murah untuk menyebarkan suatu informasi yang bahkan belum tentu kebenarannya. Informasi tentang kesehatan menjadi salah satu topik berita palsu yang banyak tersebar ke masyarakat. Cara yang berbeda untuk mendeteksi berita palsu yaitu dengan menggunakan deteksi sikap (*stance detection*). Tujuan utama dari penelitian ini adalah merancang model yang memiliki kemampuan terbaik untuk melakukan tugas *stance classification* pada konteks bahasa Indonesia. Model ini diharapkan dapat digunakan untuk berkontribusi dalam menanggulangi masalah penyebaran berita palsu, khususnya di Indonesia. Metode BiLSTM dan GRU diusulkan untuk digunakan dalam melakukan *stance classification* terhadap headline berita dengan kelas *for* (mendukung), *against* (menentang), dan *observing* (netral). *Stance classification* pada penelitian ini menggunakan data sebanyak 3.941 headline berita yang terdiri dari 563 klaim dengan 7 tanggapan. Dataset dikumpulkan dari artikel-artikel berita kesehatan berbahasa Indonesia yang diposting pada laman Facebook. Model pada penelitian ini mampu menghasilkan akurasi F1-score paling tinggi sebesar 64% dengan FastText embedding. Metode GRU dapat menjadi salah satu pilihan tepat untuk melakukan *stance classification* dengan komputasinya yang lebih sederhana. Kinerja FastText jauh lebih unggul dibandingkan dengan Word2Vec dalam melakukan pembentukan vektor kata karena mampu mengatasi masalah out-of-vocabulary (OOV).

Kata Kunci—Berbahasa Indonesia, Berita Palsu, *Bidirectional LSTM, Stance classification, GRU*

I. PENDAHULUAN

Munculnya media baru seperti Twitter maupun Facebook, memungkinkan berita dapat dipublikasikan secara real-time[1]. Siapapun dapat menjadi pembuat berita dan memberikan dampak kepada masyarakat. Bahkan para pengumpul berita sering kali mengangkat cerita dari media sosial dan mempublikasikannya kembali tanpa pemeriksaan kebenarannya. Hal ini menyebabkan berita yang mengandung kebohongan (*hoax*) mudah sekali menyebar.

Teknologi seperti *Artificial Intelligent* (AI) dan *Natural Language Processing* (NLP) menawarkan solusi bagi para peneliti untuk membangun sistem yang secara otomatis dapat mendeteksi berita palsu.

Ika Lestari, Magister Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail : ika3@mhs.stts.edu)

Esther Irawati Setiawan, Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Jawa Timur, Indonesia (e-mail : esther@stts.edu)

Namun, mendeteksi berita palsu adalah tugas yang menantang untuk diselesaikan, karena memerlukan model untuk meringkas berita dan membandingkannya dengan berita yang sebenarnya untuk dapat diklasifikasikan sebagai palsu. Selain itu, kesulitan membandingkan berita yang diusulkan dengan berita asli adalah karena sangat subjektif dan berpendirian[2]. Untuk itulah beberapa peneliti telah melakukan deteksi berita palsu dengan cara yang berbeda, yaitu menggunakan deteksi sikap (*stance*).

Salah satu topik berita palsu yang banyak tersebar ke masyarakat adalah informasi tentang kesehatan. Hal ini dikarenakan masyarakat kurang informasi terkait hal tersebut[3]. Para penyebar informasi merasa apa yang ia terima perlu untuk disebar kepada orang lain, tanpa mencari tahu terlebih dahulu kebenaran dari informasi tersebut. Media sosial menjadi sarana yang paling mudah dan murah untuk menyebarkan informasi. Bahkan platform media sosial menempati urutan tertinggi sebagai saluran penyebaran berita palsu[4]. Oleh karena itu, penelitian ini menggunakan data yang dikumpulkan dari media sosial yaitu Facebook untuk dilakukan proses klasifikasi sikap atau *stance classification*. *Stance classification* adalah proses klasifikasi terhadap sikap dari penulis teks dalam menanggapi suatu klaim berita atau informasi. Tanggapan yang diberikan dapat berupa mendukung (*for*), menentang (*against*), ataupun netral (*observing*).

Pada penelitian ini, metode *deep learning* yaitu *Bidirectional Long Short-Term Memory* (BiLSTM) dan *Gated Recurrent Unit* (GRU) diusulkan untuk digunakan dalam melakukan tugas klasifikasi sikap. Kedua model tersebut sangat ampuh dalam melakukan tugas pemrosesan data berurut. Banyak penelitian dalam bidang *stance classification* yang memanfaatkan model BiLSTM untuk melakukan proses klasifikasi, salah satunya adalah penelitian Damian [5]. Selain itu, penelitian lain yang memanfaatkan kedua model tersebut sekaligus adalah penelitian dari Gayathri [6]. Oleh karena itu, kedua model tersebut akan dimanfaatkan pada penelitian ini untuk melakukan klasifikasi sikap dalam konteks bahasa Indonesia.

Tujuan utama dari penelitian ini adalah merancang model yang memiliki kemampuan terbaik untuk melakukan tugas *stance classification* pada konteks bahasa Indonesia. Peneliti berharap model tersebut dapat digunakan untuk berkontribusi dalam menanggulangi masalah penyebaran berita palsu (*hoax*) di Indonesia.

II. PENELITIAN TERKAIT

Dengan kemajuan ilmu pengetahuan, banyak penelitian telah dilakukan terkait dengan *stance classification*. Tidak sedikit pula kompetisi diadakan guna menarik dan meningkatkan minat peneliti untuk ikut berkontribusi dalam menanggulangi masalah berita palsu. Beberapa penelitian yang telah dilakukan disajikan dalam bagian ini sebagai tinjauan literatur.

TABEL I
PENELITIAN TERKAIT STANCE CLASSIFICATION

No	Judul (tahun)	Metode	Hasil
1	<i>Stance Detection for the Fake News Challenge: Identifying Textual Relationships with Deep Neural Nets</i> (2017)	LSTMs with Independent Encoding LSTMs with Conditional Encoding LSTMs with Bidirectional Conditional Encoding Sequence-to-sequence Recurrent Model with Attention	Model ketiga memberikan kinerja terbaik, yaitu memperoleh akurasi klasifikasi lebih dari 97% pada dev set
2	<i>Stance Detection for Fake News Identification</i> (2017)	conditioned bidirectional LSTM + global features	Model mendapat skor keseluruhan sebesar 87.4% dan <i>mean F1 score</i> mencapai 69.5%
3	<i>Fake News Headline Classification using Neural Networks with Attention</i> (2017)	BiLSTM MLP dan BiLSTM Att MLP	Model BiLSTM + MLP mendapat akurasi tertinggi, yaitu sebesar 57% pada <i>batch size</i> 64, <i>embed dim</i> 300, dan <i>dense layer</i> 3
4	<i>Stance-In-Depth Deep Neural Approach to Stance Classification</i> (2018)	RNN, GRU, GRU + BiLSTM, BiGRU + BiLSTM, BiGRU, MLP, LSTM, dan BiLSTM	Model BiLSTM menghasilkan akurasi tertinggi yaitu sebesar 83.5%
5	Analisis Pendapat Masyarakat Terhadap Berita Kesehatan Indonesia Menggunakan Pemodelan Kalimat Berbasis LSTM (2020)	Long Short-Term Memory (LSTM)	Model LSTM mampu menghasilkan <i>mean F1 score</i> sebesar 71%
6	<i>Stance Classification Post Kesehatan di Media Sosial dengan FastText Embedding dan Deep Learning</i> (2020)	CNN, LSTM, BiLSTM dengan FastText dan Word2vec	Model dengan fastText mampu menghasilkan <i>F1 macro score</i> sebesar 64%

Penelitian yang dilakukan oleh Chaundry[7], Damian[5], Miller[8], dan Gayathri[6] menggunakan dataset dari *Fake News Challenge stage 1* (FNC-1) yaitu *headline* dan konten berita berbahasa Inggris. Dataset ini dapat diunduh pada halaman web *fakenewschallenge.org*. Keempat penelitian ini menggunakan *class output* sebanyak 4 (empat)

kelas, yaitu *for*, *against*, *observing*, dan *unrelated*.

Pada penelitian Chaundry[7] dilakukan banyak percobaan dengan melakukan penyetelan beberapa hyperparameter. Hyperparameter utama yang digunakan dalam penelitian tersebut yaitu *learning rate*, panjang token dari *headline* dan artikel, penyertaan tanda baca, dan menjalankan klasifikasi dalam 2, 3, atau 4 kelas. Kemudian hasil dari penelitian ini yaitu model *LSTMs with Bidirectional Conditional Encoding* berhasil melakukan deteksi sikap (*stance*) dengan akurasi klasifikasi lebih dari 97% pada dev set. Sementara itu, pada penelitian Damian[5] model yang digunakan menghasilkan skor keseluruhan mencapai 87.4% dan *mean F1 score* mencapai 69.5%. Pada penelitian tersebut, *Glove* dengan dimensi 100 digunakan sebagai representasi vektor kata yang diperbarui selama *training* dan tidak menghapus *stopwords*. Kemudian panjang artikel untuk input ke model adalah maksimal 200 kata, sedangkan panjang *headline* tidak dilakukan pemotongan.

Pada penelitian Miller[8], *Glove* juga digunakan sebagai representasi vektor kata dengan jumlah dimensi 100 dan 300. Beberapa penyetelan hyperparameter juga dilakukan pada penelitian ini hingga model BiLSTM + MLP yang digunakan berhasil menghasilkan akurasi tertinggi, yaitu sebesar 57% pada *batch size* 64, *embed dim* 300, dan *dense layer* 3. Selanjutnya pada penelitian Gayathri[6], keseluruhan model yang disebutkan pada tabel 1 dibandingkan, kemudian dianalisa dampak dari jumlah *layer* dan dilakukan pengukuran waktu *training* yang diperlukan oleh setiap model. Hasil dari penelitian ini menunjukkan bahwa model BiLSTM mampu menghasilkan akurasi tertinggi yaitu sebesar 83.5%.

Berbeda dengan keempat penelitian sebelumnya, pada penelitian yang dilakukan oleh Setiawan[9] dan Lim[10], dataset yang digunakan adalah berita berbahasa Indonesia. Selain perbedaan pada dataset, *class output* yang digunakan juga berbeda. Jika pada keempat penelitian sebelumnya menggunakan 4 *class output*, pada penelitian Setiawan[9] dan Lim[10] *class output* yang digunakan sebanyak 3 (tiga) kelas, yaitu *for*, *against*, dan *observing*. Pada penelitian Setiawan [9], model LSTM yang digunakan berhasil melakukan deteksi sikap (*stance*) dengan *mean F1 score* sebesar 71%. Sementara itu, model yang digunakan pada penelitian Lim[10] yaitu BiLSTM dengan *word embedding* FastText menghasilkan akurasi *F1-score* sebesar 64%.

Penelitian ini merupakan pengembangan penelitian dalam bidang *stance classification* berbahasa Indonesia. Pengembangan yang dilakukan adalah dengan menggunakan model GRU sebagai *classifier* yang kemudian dibandingkan kinerjanya dengan model BiLSTM. Hal ini dilakukan untuk mengetahui model mana yang lebih akurat dalam menentukan *stance* dari sebuah judul berita yang menanggapi klaim. Selain itu, *classifier stance* dengan menggunakan model GRU belum pernah diuji coba pada penelitian Setiawan[9] dan Lim[10].

A. *Stance Classification*

Stance classification merupakan sub-domain dari sentiment analysis. *Stance classification* didefinisikan

sebagai tugas untuk mengklasifikasi hubungan antara dua teks. Dalam penelitian ini, hubungan antara dua teks tersebut dikelompokkan menjadi 3 (tiga), yaitu mendukung (*for*), menentang (*against*), dan netral (*observing*). Penelitian – penelitian *stance classification* sebelumnya digunakan untuk mendeteksi sikap peserta dalam debat online[11], esai mahasiswa, dan debat kongres[12]. Penelitian tersebut bekerja dengan adanya target yang spesifik. Berbeda dengan penelitian yang dilakukan pada sebuah kompetisi bernama *fake news challenge stage 1* (FNC-1) dengan topik *stance detection*. Pada kompetisi ini, dataset yang digunakan adalah *emergent dataset*[1]. Dataset ini terdiri dari sekitar 50.000 pasangan *headline-artikel* yang masing – masing diberi label dengan *unrelated, discuss, agree, atau disagree*.

B. Bidirectional Long Short-Term Memory (BiLSTM)

Pada bidang *Natural Language Processing* (NLP), khususnya *stance classification* atau *stance detection* telah banyak yang menggunakan model *biLSTM*. Yuanyu[13] telah berhasil menggunakan model *biLSTM* untuk melakukan *stance detection* pada dataset *Semeval-2016 Task 6.A (English dataset)* dan *NLPCC-2016 Stance Detection Shared Task (Chinese dataset)*. Selain itu, Isabelle[14] juga menggunakan model *biLSTM* pada dataset *SemEval 2016 Task 6 Twitter Stance Detection corpus*. Kemudian pada dataset yang berbeda yaitu *emergent*[1] *FNC-1*, *Damian*[5] dan *Miller*[8] juga telah berhasil menggunakan model *biLSTM* dalam penelitiannya.

C. Gated Recurrent Unit (GRU)

Selain menggunakan model *BiLSTM*, model lain yang sering digunakan dalam penelitian bidang NLP adalah *GRU*. Pada penelitian identifikasi berita palsu, model *GRU* mampu menghasilkan akurasi yang tidak kalah baik dengan *BiLSTM*. *Gayathri*[6] telah berhasil menerapkan model *GRU* untuk melakukan *stance classification* dengan *emergent dataset* (*FNC-1*)[1]. Selain itu, *Reddy*[15] juga telah memanfaatkan model *GRU* untuk mengikuti kompetisi *UrduFake FIRE-2020* dengan menggunakan dataset *Urdu Fake News Dataset*.

III. GAMBARAN DATASET

Dataset yang digunakan dalam penelitian ini adalah *Indonesian News Stance Dataset*[9] yang diperbarui pada penelitian *Lim*[10]. Pembaruan dataset ini dilakukan dengan mengumpulkan artikel – artikel berita kesehatan berbahasa Indonesia yang dipost pada laman Facebook. Pengambilan dataset tersebut adalah dari judul artikel yang dibagikan, judul pada gambar yang dipost, atau teks judul pada post. Dataset terdiri dari id, judul berita (*headline*) sebagai klaim, sumber, jumlah *like*, jumlah *comment*, judul berita (*headline*) lain sebagai tanggapan, id tanggapan, sumber tanggapan, jumlah *like* tanggapan, jumlah *comment* tanggapan, dan kelas *stance*. Kemudian dataset ini diberi label secara manual. Label *stance* yang digunakan meliputi :

- *For* : *headline* tanggapan mendukung *headline* klaim
- *Against* : *headline* tanggapan menentang *headline* klaim
- *Observing* : *headline* tanggapan tidak memberikan penilaian terhadap *headline* klaim atau bersifat netral.

Dalam melakukan uji coba pada penelitian ini, dilakukan penambahan satu judul artikel yang menanggapi setiap klaim. Penambahan ini dilakukan untuk mengetahui dampak dari jumlah data terhadap akurasi yang dihasilkan oleh model. Akibatnya jumlah dataset yang digunakan dalam penelitian ini adalah sebanyak 3.941 *headline* berita. Dataset terdiri dari 563 *headline* klaim, dan 7 *headline* berita lain yang menanggapi. Pada awalnya, jumlah dataset yang digunakan pada penelitian *Lim*[10] adalah sebanyak 3.378 *headline* berita, dengan 6 *headline* berita lain yang menanggapi klaim. Distribusi dataset ini ditunjukkan pada tabel II. Contoh dataset yang digunakan dalam penelitian ini ditunjukkan pada tabel III. Pada penelitian ini, data yang digunakan hanya id, *headline* klaim, *headline* tanggapan, dan kelas *stance*.

TABEL II
DISTRIBUSI DATASET

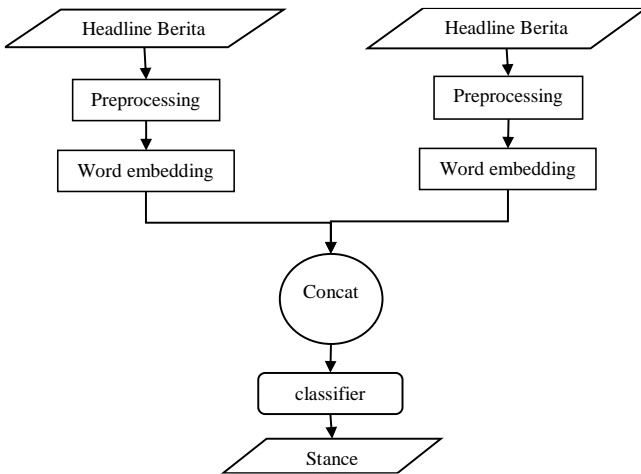
No	Stance	Jumlah	Persentase (%)
1	<i>Against</i>	1.275	32.4
2	<i>For</i>	1.391	35.3
3	<i>Observing</i>	1.275	32.4

TABEL III
CONTOH DATASET

Headline Klaim	Headline Tanggapan	Stance
	Waspada Risiko Penyakit Ini Jika Tidur Siang Terlalu Lama	<i>for</i>
	Terlalu Lama Tidur Siang Memicu Penyakit Jantung	<i>for</i>
Awas, Ini Bahaya Tidur Siang yang Lebih dari Sejam	Penting gak sih tidur siang bagi si kecil???	<i>observing</i>
	Kapan Waktu yang Tepat untuk Tidur Siang?	<i>observing</i>
	7 Manfaat Tidur Siang yang Tak Banyak Diketahui	<i>against</i>
	MANFAAT TIDUR SIANG	<i>against</i>
	10 Manfaat Tidur Siang, Sangat Baik untuk Menjaga Kondisi Tubuh	<i>against</i>

IV. METODOLOGI PENELITIAN

Bidirectional long short-term memory (Bi-LSTM) telah sukses digunakan untuk tugas pemrosesan bahasa alami. Dengan dataset *emergent*, *Damian*[5] telah berhasil melakukan deteksi sikap dengan menggunakan model *Bi-LSTM* dan menghasilkan *score* sebesar 87.4% dan *mean F1 score* sebesar 69.5%. Berdasarkan hal ini, penulis mengadopsi model *Bi-LSTM* untuk melakukan deteksi sikap (*stance detection*) pada berita berbahasa Indonesia. Pada penelitian ini diberikan batasan yaitu dengan tidak melakukan proses klasifikasi untuk data dengan kedua input *headline* berita membahas topik yang berbeda (*unrelated*). Alur sistem dari penelitian ini ditunjukkan pada gambar 2.



Gambar. 2. Alur Sistem Penelitian

A. Preprocessing

Setiap input yaitu *headline* klaim dan *headline* tanggapan akan dilakukan preprocessing terlebih dahulu. Tahapan preprocessing yang dilakukan dalam penelitian ini terdiri dari *case folding*, *tokenizing*, *filtering*, dan *stemming*. *Case folding* yaitu proses penyamaan case dalam sebuah dokumen (*lowercase*). *Tokenizing* yaitu proses memisahkan deretan kata dalam kalimat menjadi token atau potongan kata tunggal. Proses *tokenizing* dilakukan dengan menggunakan *word_tokenize* yang dimiliki oleh *library* nltk. *Filtering* yaitu proses membuang kata – kata tidak penting dari hasil token, seperti “yang”, “di”, “dan”, dan lain - lain. Proses *filtering* ini berdasarkan *stopwords* dari Tala[16]. Selain menghapus kata yang tidak penting, dalam proses *filtering* juga dilakukan penghapusan karakter spesial kecuali tanda tanya, tanda hubung, dan angka 0 – 9. Dan yang terakhir yaitu *stemming*, adalah proses pengembalian suatu kata berimbuhan ke bentuk dasarnya. Proses *filtering* dan *stemming* yang dilakukan dalam penelitian ini menggunakan library Sastrawi.

B. Word Embedding

Setelah input melalui tahap preprocessing, selanjutnya dilakukan *word embedding*. Dalam penelitian ini, *word embedding* yang digunakan adalah Word2Vec dan FastText. Algoritma Word2Vec diciptakan oleh Mikolov[17] pada tahun 2013. Dalam penelitian ini, Word2Vec yang digunakan adalah *pre-trained* Word2Vec dengan ukuran dimensi 300. *Pre-trained* Word2Vec ini dapat diakses pada[18]. Sedangkan FastText *embedding* yang digunakan adalah cc.id.300.bin dengan ukuran dimensi 300. FastText *embedding* merupakan pengembangan dari Word2Vec. Algoritma ini diciptakan oleh Bojanowski[19] pada tahun 2017.

Pada tahap ini, sebuah input berupa teks atau string akan dikonversi menjadi angka atau vektor. Hal ini agar input tersebut dapat diolah oleh arsitektur *deep learning*. Selain input harus berupa angka atau vektor, input harus memiliki bentuk (*shape*) dan ukuran (*size*) yang sama. Namun secara alamiah, setiap kalimat input tidak memiliki jumlah kata yang sama. Oleh karena itu, diperlukan proses *padding* menggunakan *pad_sequences* milik Tensorflow. Kita juga dapat menentukan jumlah maksimal kata untuk setiap


kalimat. Sebelum dilakukan proses *padding*, kalimat input perlu ditokenisasi terlebih dahulu menggunakan *tokenizer tool* milik Tensorflow.

C. Classifier

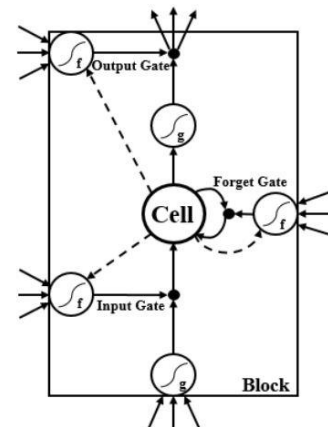
1) Klasifikasi dengan Bidirectional LSTM (BiLSTM)

Setelah tahap *word embedding* selesai dilakukan, kemudian kedua vektor dari *headline* berita akan digabung (*concat*) untuk dijadikan sebagai input dari *classifier*. Proses klasifikasi dengan BiLSTM adalah untuk menentukan sikap (*stance*) dari *headline* berita tanggapan terhadap *headline* berita klaim. Sikap (*stance*) yang digunakan dalam penelitian ini adalah *for*, *against*, dan *observing*.

Arsitektur dari BiLSTM terdiri dari *forward* LSTM dan *backward* LSTM. BiLSTM dapat menyesuaikan data dari arah maju (*forward*) dan mundur (*backward*), kemudian menggabungkan prediksi. *Forward* dan *backward* pada BiLSTM dapat meningkatkan jumlah informasi yang tersedia ke jaringan dan konteks yang tersedia untuk algoritma, misalnya mengetahui kata apa yang segera mengikuti dan mendahului kata dalam kalimat. Untuk memahami kata dalam NLP, terkadang tidak hanya dibutuhkan kata sebelumnya, melainkan juga kata yang akan datang. Perbedaan arsitektur antara LSTM dan BiLSTM ditunjukkan pada gambar 3[20]. Sementara itu, struktur dari satu sel LSTM ditunjukkan pada gambar 4[21].



Gambar. 3. Perbedaan Arsitektur antara LSTM dan BiLSTM



Gambar. 4. Struktur satu sel LSTM

LSTM memiliki *cell memory* yaitu tambahan informasi sinyal yang diberikan dari satu *time step* ke *time step* berikutnya. Satu sel LSTM memiliki 3 (tiga) mekanisme gerbang, yaitu *forget gate*, *input gate*, dan *output gate*. Langkah kerja dari LSTM adalah dimulai melalui komponen

forget gate (f_t) yang ditunjukkan pada (1). Pada gerbang ini ditentukan informasi yang tidak dibutuhkan agar dibuang dari *memory cell* (C_{t-1}) dengan menggunakan fungsi sigmoid. Pada *forget gate*, nilai vektor *hidden state* dalam *time step* sebelumnya (h_{t-1}) dan nilai vektor input x dalam *time step* t (x_t) dibaca, kemudian menghasilkan angka antara 0 (artinya lupakan elemen) dan 1 (artinya jaga elemen) untuk setiap elemen dalam C_{t-1} .

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Langkah selanjutnya adalah menentukan informasi yang akan diperbarui melalui *input gate* (i_t). Pada saat yang sama, juga dihasilkan kandidat vektor *memory cell* yang baru (\tilde{C}_t). Hal ini ditunjukkan pada (2) dan (3). Hasil dari kedua proses ini kemudian digabungkan untuk mengupdate C_t . Dalam melakukan update C_t dari C_{t-1} dilakukan perkalian antara C_{t-1} dengan f_t untuk melupakan informasi, kemudian mengalikan \tilde{C}_t dengan i_t untuk memutuskan seberapa banyak kandidat C_t disertakan, lalu keduanya dijumlahkan. Proses update ini ditunjukkan pada (4).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

Kemudian langkah terakhir dari LSTM adalah menentukan *output* yang didasarkan pada nilai C dan dilewatkan ke suatu filter. Dalam langkah ini terdapat 3 tahapan. Pertama, menjalankan gerbang sigmoid yang disebut *output gate* (o_t) untuk memutuskan bagian – bagian apa dari C yang akan dihasilkan (5). Kedua, melewati C melalui tanh untuk membuat nilainya menjadi antara -1 dan 1. Terakhir, mengalikan *output* gerbang sigmoid tadi sehingga menghasilkan bagian yang diputuskan sesuai dengan (6).

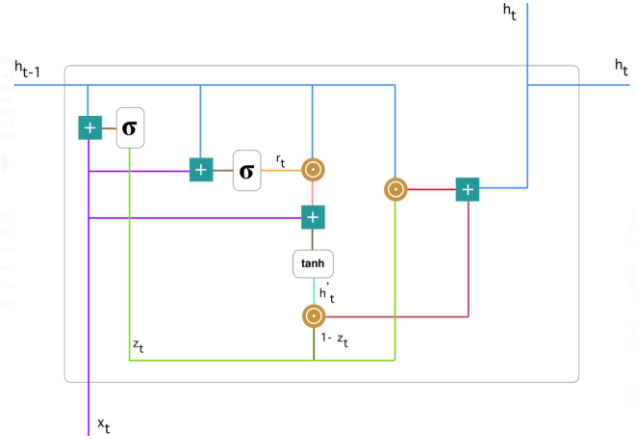
$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$s_t = o_t * \tanh(C_t) \quad (6)$$

2) Klasifikasi dengan Gated Recurrent Unit (GRU)

GRU juga digunakan sebagai *classifier* dalam penelitian ini. Input yang digunakan pada model GRU adalah teks yang telah melalui proses *preprocessing* dan *word embedding*, yakni berupa vektor dari *headline* berita. Model GRU akan melakukan proses klasifikasi, yaitu apakah *headline* berita tanggapan mengandung salah satu sikap (*stance*) terhadap *headline* berita klaim.

Model GRU pertama kali diperkenalkan oleh Cho[22] dan Chung[23] pada tahun 2014. Model ini diciptakan untuk mengatasi masalah *vanishing gradient* pada *Recurrent Neural Network* (RNN). Model GRU dipilih untuk digunakan dalam penelitian ini adalah karena GRU memiliki rancangan yang hampir sama dengan LSTM, bahkan terkadang hasil dari kedua model ini juga sama baiknya. Arsitektur dari GRU ditunjukkan pada gambar 5[24].



Gambar. 5. Struktur satu sel GRU

Dalam satu struktur sel GRU terdapat 2 *gate*, yaitu *update gate* dan *reset gate* yang digunakan untuk mengatasi masalah *vanishing gradient* dari struktur RNN biasa. Langkah kerja dari GRU adalah dimulai dengan menghitung *update gate* (z_t) untuk langkah waktu t dengan formula ditunjukkan pada (7). Pada langkah ini, x_t yang masuk ke jaringan akan dikalikan dengan bobotnya sendiri ($W_{(z)}$). Hal ini juga berlaku untuk $h_{(t-1)}$ yang menyimpan informasi untuk unit $t - 1$ sebelumnya dan dikalikan dengan bobotnya sendiri ($U_{(z)}$). Hasil dari kedua proses ini kemudian dijumlahkan dan fungsi aktivasi *sigmoid* diterapkan. Hasil dari *update gate* adalah antara 0 dan 1. Fungsi dari *update gate* ini adalah untuk membantu model menentukan berapa banyak informasi masa lalu akan diteruskan ke masa depan. Sehingga model dapat menyalin semua informasi masa lalu dan menghilangkan masalah *vanishing gradient*.

$$z_t = \sigma(W^{(z)} x_t + U^{(z)} h_{t-1}) \quad (7)$$

Langkah selanjutnya adalah *reset gate* yang berfungsi untuk membantu model melupakan informasi masa lalu. Formula dari *reset gate* ditunjukkan pada (8). Formula ini hampir sama dengan *update gate*, hanya berbeda pada bobotnya. Kemudian pada konten memori baru akan menggunakan *reset gate* untuk menyimpan informasi yang relevan dari masa lalu dengan formula (9). Langkah terakhir, jaringan perlu menghitung h_t (vektor yang menyimpan informasi untuk unit saat ini) dan meneruskannya ke jaringan. Untuk melakukan hal tersebut, langkah ini memerlukan *update gate*. Fungsi dari langkah terakhir ini adalah untuk menentukan informasi yang harus dikumpulkan dari konten memori saat ini (h_t^{\sim}) dan dari langkah sebelumnya (h_{t-1}). Formula dari langkah ini ditunjukkan pada (10).

$$r_t = \sigma(W^{(r)} x_t + U^{(r)} h_{t-1}) \quad (8)$$

$$h_t^{\sim} = \tanh(W_x + r_t \circ U h_{t-1}) \quad (9)$$

$$h_t = z_t \circ h_{t-1} + (1 - z_t) \circ h_t^{\sim} \quad (10)$$

D. Sistem Evaluasi Performa

Dalam penelitian ini, akurasi diukur menggunakan *F1-score* dari setiap label dan *macro-average F1-score*. *F1-score* diperoleh dari *harmonic mean* antara *precision* dan *recall*. Rentang nilai dari *F1-score* adalah antara 0 hingga 1. Perhitungan *F1-score* dapat dilihat pada (11).

$$F1-score = \frac{2 * precision * recall}{precision + recall} \quad (11)$$

Precision adalah tingkat ketepatan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh sistem. Sementara, *recall* adalah persentase item positif diidentifikasi dengan benar. Perhitungan *precision* dan *recall* dapat dilihat pada (12) dan (13).

$$precision = \frac{tp}{tp + fp} \quad (12)$$

$$recall = \frac{tp}{tp + fn} \quad (13)$$

dimana *tp* (*true positive*) adalah banyaknya tebakan positif dengan *target class* sebenarnya positif, *fp* (*false positive*) adalah banyaknya tebakan positif padahal *target class* yang sesungguhnya adalah negatif, sedangkan *fn* (*false negative*) adalah banyaknya tebakan negatif dengan *actual class* positif.

V. HASIL EKSPERIMEN

Dalam penelitian *stance classification* ini dilakukan percobaan dengan beberapa parameter dan metode yang berbeda. Dataset yang digunakan untuk melakukan uji coba adalah 20% dari keseluruhan data. Dalam penelitian ini, *macro-average F1-score* digunakan untuk mengetahui akurasi prediksi dari semua label. Sementara itu, *F1-score* digunakan untuk mengetahui akurasi prediksi pada setiap label. Proses percobaan pada penelitian ini dilakukan dengan menguji coba model sebanyak sepuluh *seed*, sehingga terdapat 10 *classification report*. Kemudian hasil uji coba yang digunakan adalah rata – rata *F1-score* dan *macro-average F1-score* dari 10 *classification report* tersebut. Hal tersebut juga dilakukan pada penelitian Lim[10]. Parameter yang digunakan untuk melakukan uji coba terdiri dari: jumlah dataset, jenis *word embedding*, jenis *classifier*, dan *dropout rate*. Beberapa parameter yang diuji coba dalam penelitian ini mengacu dari penelitian Mrowca[5] dan Lim[10].

A. Jumlah Dataset

Seperti yang telah dibahas pada section III tentang gambaran dataset bahwa dilakukan penambahan *headline* tanggapan untuk penelitian ini. Pada penelitian ini dilakukan perbandingan hasil akurasi model dengan menggunakan data sebanyak 3.378 (data asli dari penelitian Lim[10]) dan 3.941 (dataset sudah ditambah). Hasil penelitian ditunjukkan pada tabel IV. Hasil penelitian menunjukkan bahwa dengan penambahan dataset sebanyak 563 data tidak berpengaruh secara signifikan terhadap hasil akurasi model. Dengan melakukan penambahan dataset hanya mampu meningkatkan akurasi *F1-score* sebanyak 2% dari 62% menjadi 64% pada model BiLSTM dan GRU.

B. Jenis Word Embedding

Jenis *word embedding* yang digunakan dalam penelitian ini adalah *pre-trained* Word2Vec dan FastText dengan dimensi keduanya adalah 300. Penggunaan Word2Vec sebagai *word embedding* dalam penelitian ini adalah mengacu pada penelitian Gayathri[6] dan Setiawan[9]. Sedangkan FastText mengacu pada penelitian Lim[10] yang mana cc.id.300.bin

cocok digunakan untuk *stance classification* dengan fitur kalimat.

Hasil uji coba untuk perbandingan kinerja *word embedding* yang digunakan dalam penelitian ini ditunjukkan pada tabel V. Pada tabel tersebut terlihat bahwa *word embedding* dengan menggunakan FastText mampu menghasilkan akurasi *F1-score* sebesar 64%, jauh lebih tinggi dibandingkan dengan Word2Vec yang hanya mampu menghasilkan akurasi *F1-score* sebesar 51%. Kemudian dengan menggunakan Word2Vec, GRU mampu lebih unggul 6% dibandingkan dengan BiLSTM.

C. Jenis Classifier

Selain melakukan percobaan dengan *word embedding* yang berbeda, penelitian ini juga melakukan percobaan dengan membandingkan dua jenis *classifier* yang berbeda. Jenis *classifier* tersebut yaitu BiLSTM dan GRU. Pada penelitian Gayathri[6], model BiLSTM mampu menghasilkan akurasi paling besar dibandingkan dengan GRU. Namun pada penelitian ini, tidak ada perbedaan hasil akurasi dari model BiLSTM dan GRU. Kedua model tersebut mampu menghasilkan akurasi *F1-score* sebesar 64%. Hasil penelitian ini dapat dilihat pada tabel VI.

D. Dropout Rate

Penelitian ini menguji coba *dropout rate* dengan nilai 0.25, 0.5, 0.75, dan 0.99. Keempat nilai tersebut diuji cobakan kepada BiLSTM dan GRU dengan *FastText embedding*. Hasil penelitian ini ditunjukkan pada tabel VII. Dari tabel tersebut terlihat bahwa pada model BiLSTM dan GRU, nilai *dropout rate* yang semakin tinggi justru memperburuk akurasi model yang dihasilkan.

Pada *dropout rate* dengan nilai 0.75, akurasi *F1-score* pada model GRU mengalami penurunan sebesar 1% dari 64% menjadi 63%. Kemudian setelah nilai *dropout rate* dinaikkan menjadi 0.99, justru akurasi *F1-score* model GRU mengalami penurunan drastis sebesar 4% dari 63% menjadi 59%. Hal ini juga berlaku pada model BiLSTM, nilai *dropout rate* sebesar 0.99 juga memperburuk akurasi *F1-score*. Pada *dropout rate* 0.99 akurasi model BiLSTM mengalami penurunan sebesar 2% dari 64% menjadi 62%.

TABEL IV
HASIL UJI COBA DENGAN JUMLAH DATASET YANG BERBEDA

Jumlah Dataset	F1 for	F1 against	F1 observing	F1-score	Macro-avg F1-score
3.378					
BiLSTM	0.58	0.50	0.77	0.62	0.62
GRU	0.52	0.51	0.81	0.62	0.61
3.941					
BiLSTM	0.60	0.50	0.81	0.64	0.64
GRU	0.61	0.53	0.79	0.64	0.64

TABEL V
HASIL UJI COBA DENGAN JENIS WORD EMBEDDING

Word Embedding	F1 for	F1 against	F1 observing	F1-score	Macro-avg F1-score
Word2Vec + BiLSTM	0.45	0.41	0.55	0.48	0.47
Word2Vec + GRU	0.53	0.51	0.56	0.54	0.53
Rata - rata				0.51	0.50
FastText + BiLSTM	0.60	0.50	0.81	0.64	0.64
FastText + GRU	0.61	0.53	0.79	0.64	0.64
Rata - rata				0.64	0.64

TABEL VI
HASIL UJI COBA DENGAN JENIS CLASSIFIER YANG BERBEDA

Jenis Classifier	F1 for	F1 against	F1 observing	F1-score	Macro-avg F1-score
BiLSTM	0.60	0.50	0.81	0.64	0.64
GRU	0.61	0.53	0.79	0.64	0.64

TABEL VII
HASIL UJI COBA DENGAN PARAMETER DROPOUT RATE

Dropout Rate	F1 for	F1 against	F1 observing	F1-score	Macro-avg F1-score
BiLSTM					
0.25	0.60	0.51	0.80	0.64	0.64
0.5	0.60	0.50	0.81	0.64	0.64
0.75	0.59	0.53	0.80	0.64	0.64
0.99	0.61	0.41	0.79	0.62	0.60
GRU					
0.25	0.60	0.51	0.81	0.64	0.64
0.5	0.61	0.53	0.79	0.64	0.64
0.75	0.60	0.49	0.80	0.63	0.63
0.99	0.60	0.37	0.77	0.59	0.58

Hasil akhir dari penelitian ini memperlihatkan bahwa GRU mampu memberikan hasil yang setara dengan BiLSTM. Jika dibandingkan dengan penelitian sebelumnya, yaitu penelitian Lim[10], model BiLSTM memberikan hasil yang sama yaitu akurasi *F1-score* sebesar 64%. Namun jika dibandingkan dengan penelitian yang dilakukan oleh Setiawan[9], hasil penelitian ini menunjukkan adanya penurunan drastis pada model dengan *word embedding* Word2Vec. Hasil akhir dari penelitian Setiawan[9] adalah akurasi *F1-score* sebesar 71%, sedangkan pada penelitian ini, model dengan *word embedding* Word2Vec mampu menghasilkan akurasi *F1-score* sebesar 51%. Penurunan sebanyak 20% ini disebabkan karena Word2Vec yang digunakan pada penelitian Setiawan[9] adalah *on-trained* Word2Vec yang mana representasi vektor yang dihasilkan lebih disesuaikan terhadap arsitektur tugas *stance classification* yang digunakan.

VI. KESIMPULAN DAN SARAN

Stance classification pada berita berbahasa Indonesia menghasilkan akurasi tertinggi sebesar 64% dengan menggunakan algoritma *bidirectional LSTM* (Bi-LSTM) maupun *Gated Recurrent Unit* (GRU). Kedua model ini menghasilkan nilai akurasi *F1-score* yang sama dengan menggunakan *word embedding* FastText. Dengan demikian, model GRU yang mana merupakan varian RNN dengan komputasi sederhana dapat menjadi salah satu pilihan tepat untuk melakukan tugas klasifikasi, khususnya *stance classification*. Kemudian performa kinerja dari FastText jauh lebih akurat dibandingkan dengan Word2Vec. Hal ini disebabkan karena FastText *embedding* memiliki kemampuan dalam menangani kata – kata yang belum pernah ditemui sebelumnya atau yang disebut dengan *out-of-vocabulary* (OOV).

Penelitian mengenai *stance classification* pada dataset bahasa Indonesia ini memiliki peluang besar untuk terus dikembangkan. Salah satu pengembangan yang dapat dilakukan adalah dengan mencoba metode representase kata yang lain seperti Bert *Embedding*.

DAFTAR PUSTAKA

- [1] W. Ferreira and A. Vlachos, "Emergent: a novel data-set for stance classification," in *Proceedings of the 2016 conference of the North American chapter of the association for computational linguistics: Human language technologies*, 2016, pp. 1163–1168.
- [2] A. Thota, "Fake News Detection : A Deep Learning Approach," *SMU Data Sci. Rev. Vol. 1 No. 3, Artic. 10*, vol. 1, no. 3, 2018.
- [3] A. M. Hasan, "Info Hoax Soal Kesehatan Paling Banyak Beredar di Masyarakat," <https://tirto.id/>, 2017.
- [4] "Hasil Survey Wabah HOAX Nasional 2019," <https://mastel.id/>, 2019.
- [5] D. Mrowca and E. Wang, "Stance detection for fake news identification," *Eliaswang.Com*, 2017.
- [6] G. Rajendran, B. Chitturi, and P. Poornachandran, "Stance-In-Depth Deep Neural Approach to Stance Classification," *Procedia Comput. Sci.*, vol. 132, no. Iccids, pp. 1646–1653, 2018, doi: 10.1016/j.procs.2018.05.132.
- [7] P. Chaudhry, A. K., Baker, D. & Thun-Hohenstein, "Stance Detection for the Fake News Challenge: Identifying Textual Relationships with Deep Neural Nets," *Stanford*, pp. 1–10, 2017.
- [8] K. Miller and A. Oswald, "Fake News Headline Classification using Neural Networks with Attention."
- [9] E. I. Setiawan *et al.*, "Analisis Pendapat Masyarakat terhadap Berita Kesehatan Indonesia menggunakan Pemodelan Kalimat berbasis LSTM (Indonesian Stance Analysis of Healthcare News using Sentence Embedding Based on LSTM)," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 9, no. 1, pp. 8–17, 2020.
- [10] E. Lim, E. I. Setiawan, and J. Santoso, "Stance Classification Post Kesehatan di Media Sosial Dengan FastText Embedding dan Deep Learning," pp. 65–73, 2020.
- [11] K. S. Hasan and V. Ng, "Stance classification of ideological debates: Data, models, features, and constraints," in *Proceedings of the Sixth International Joint Conference on Natural Language Processing*, 2013, pp. 1348–1356.
- [12] M. Thomas, B. Pang, and L. Lee, "Get out the vote: Determining support or opposition from Congressional floor-debate transcripts," *COLING/ACL 2006 - EMNLP 2006 2006 Conf. Empir. Methods Nat. Lang. Process. Proc. Conf.*, no. July, pp. 327–335, 2006.
- [13] Y. Yang, B. Wu, K. Zhao, and W. Guo, "Tweet stance detection: A two-stage DC-BiLSTM model based on semantic attention," *Proc. - 2020 IEEE 5th Int. Conf. Data Sci. Cyberspace, DSC 2020*, pp. 22–29, 2020, doi: 10.1109/DSC50466.2020.00012.
- [14] I. Augenstein, T. Rocktäschel, A. Vlachos, and K. Bontcheva, "Stance detection with bidirectional conditional encoding," 2016, doi: 10.18653/v1/d16-1084.
- [15] S. M. Reddy, C. Suman, S. Saha, and P. Bhattacharyya, "A GRU-

- based fake news prediction system: Working notes for UrduFake-FIRE 2020,” *CEUR Workshop Proc.*, vol. 2826, pp. 464–468, 2020.
- [16] F. Z. Tala, “A Study of Stemming Effects on Information Retrieval in Bahasa Indonesia,” Universiteit van Amsterdam, The Netherlands.
- [17] T. Mikolov, G. Corrado, K. Chen, and J. Dean, “Vector Space,” pp. 1–12.
- [18] deryrahman, “Word2Vec Bahasa Indonesia,” <https://github.com/>, 2019.
- [19] P. Bojanowski, E. Grave, A. Joulin, and T. Mikolov, “Enriching Word Vectors with Subword Information,” *Trans. Assoc. Comput. Linguist.*, vol. 5, 2017, doi: 10.1162/tacl_a_00051.
- [20] A. T. Mohan and D. V. Gaitonde, “A Deep Learning based Approach to Reduced Order Modeling for Turbulent Flow Control using LSTM Neural Networks,” *Cornell Univ.*, no. April, 2018.
- [21] Alex Graves, “Supervised Sequence Labelling with Recurrent Neural Networks,” *Springer, Berlin, Heidelb.*, 2012, doi: <https://doi.org/10.1007/978-3-642-24797-2>.
- [22] K. Cho, “Learning Phrase Representations using RNN Encoder – Decoder for Statistical Machine Translation,” *Proc. 2014 Conf. Empir. Methods Nat. Lang. Process. (EMNLP)*, Doha, Qatar, pp. 1724–1734, 2014.
- [23] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, “Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling,” pp. 1–9, 2014.
- [24] Simeon Kostadinov, “Understanding GRU Networks,” 2017.

Ekstraksi Ulasan Sentimen Film dari Twitter dengan Naïve Bayes pada Situs Web Media Sosial Penggemar Film

Adri Gabriel Sooi, *Fakultas Teknik, Prodi Ilmu Komputer Universitas Katolik Widya Mandira Kupang*,
Melania Laniwati, *Departemen Teknik Informatika Institut Sains dan Teknologi Terpadu Surabaya*.

Abstrak— Film dianggap sebagai bentuk seni serta merupakan sumber hiburan yang populer. Pembuatan penelitian ini diharapkan bisa membantu orang Indonesia untuk mendapatkan informasi tentang film serta membaca review dari film. Review film yang ada pada website ini didapatkan dari user-user lokal maupun dari Twitter. Sistem mengekstraksi dan mengkategorikan isi sentiment dari sebuah barisan teks tweet dengan menggunakan metodologi Basic Unified Process. Proses klasifikasi sentiment yang ada bertujuan untuk mengklasifikasi review sebagai positif/negatif. Seluruh tweet akan diproses melalui Feature Reduction dan Normalisasi. Proses Feature Reduction akan menghapus hashtag, username, link, dan tanda baca pada tweets. Pada proses Normalisasi, seluruh singkatan dan kata bukan baku pada tweets akan diganti. Penelitian ini menggunakan sistem Rule-Based dalam menentukan apakah tweet tersebut merupakan review film atau bukan. Penulis menggunakan algoritma Naïve Bayes untuk mengklasifikasi sentiment (positif/negatif) dari review. Penulis telah melakukan 8 buah pengujian, masing-masing 4 kali untuk pengujian sistem Rule-Based dan Naïve Bayes Classifier. Total data tweet yang diujicobakan adalah sebanyak 6.323, dan hasil akhir paling optimal yang didapatkan oleh sistem terhadap Rule-Based System menghasilkan akurasi sebesar 82,64% dan terhadap Naïve Bayes Classifier sebesar 74,09%. Dari hasil pengujian paling optimal ini, sistem mendapatkan nilai recall dan presisi masing-masing sebesar 71,44% dan 77,92% untuk Rule-Based System, serta 83,77% dan 77,65% untuk Naïve Bayes.

Kata Kunci—Naïve Bayes Classifier, Natural Language Processing, Rule-Based System, Sentiment Analysis.

I. PENDAHULUAN

Saat ini dunia teknologi semakin berkembang, terutama sejak meluasnya perkembangan internet. Hal yang mendorong perkembangan tersebut sebenarnya adalah peningkatan kebutuhan manusia akan berbagai bentuk dan jenis informasi, yang akan digunakan untuk berbagai macam keperluan manusia seperti halnya untuk mendapatkan informasi. Pada kota-kota besar di Indonesia di mana tantangan

semakin besar dan tingkat stress semakin tinggi, manusia semakin membutuhkan sarana hiburan yang tepat untuk meredakan tingkat stress. Salah satu sarana hiburan yang sehat dan populer saat ini adalah menonton film. Menonton film kini semakin populer di masyarakat Indonesia kini, didukung pula dengan fakta bahwa perfilman lokal semakin lebih baik.

Hingga saat ini, masyarakat di Indonesia tidak sepenuhnya bisa menentukan apakah suatu film layak ditonton di teater atau tidak, mengingat bahwa Cinema 21 yang merupakan penguasa pangan teater di Indonesia, tidak menawarkan sistem rating dan review sebuah film. Karena kelayakan suatu film untuk ditonton di teater tidak bisa ditentukan hanya berdasarkan sinopsis saja, masyarakat sering kali tertipu dan akhirnya merasa kecewa setelah menonton suatu film di teater [1]. Hal ini didukung pula dengan kenyataan bahwa banyak film lama yang baru saja ditampilkan di teater Indonesia. Masyarakat memang bisa saja melihat rating dari film secara manual melalui website atau aplikasi IMDB ataupun Metacritic, tetapi mengingat bahwa selera bangsa tidak selalu sepadan dengan bangsa lain, banyak film yang memiliki rating tinggi tetapi tidak diminati oleh masyarakat.

Sejauh ini, masih belum banyak terdapat aplikasi ataupun website lokal yang memperbolehkan pengguna untuk berbagi rating dan review mereka terhadap suatu film. Para penggemar film masih belum memiliki wadah untuk menyalurkan pengalaman mereka selama menonton suatu film. Tujuan utama dari dibuatnya penelitian ini adalah untuk mengatasi masalah di atas. Pada website yang akan dibuat ini, pengguna bisa membagikan pengalaman dan kesan pengguna selama menonton film dengan meninggalkan rating dan review terhadap suatu film. Pengguna bisa pula melihat film yang sedang tayang dan akan tayang, beserta dengan rating dari film yang sedang tayang, baik dari rating lokal (rating dari sesama pengguna) maupun rating yang diambil dari IMDB dan Metacritic, serta ekstraksi banyaknya respons negatif/positif dari komentar film yang ada di Twitter.

II. TINJAUAN PUSTAKA

Pada berikut ini akan menjelaskan mengenai landasan-landasan teori apa saja yang dijadikan sumber dalam pembuatan penelitian ini. Ada beberapa teori penunjang yang akan digunakan untuk membuat sekaligus mengembangkan aplikasi yang dibuat. Pada beberapa bagian akan disertakan

Adri Gabriel Sooi, Fakultas Teknik, Prodi Ilmu Komputer. Universitas Katolik Widya Mandira, Kupang, Indonesia (email: adrigabriel@unwira.ac.id)
Melania Laniwati, Departemen Teknik Informatika, Sekolah Tinggi Teknik Surabaya, Surabaya, Jawa Timur, Indonesia

beberapa contoh dari segmen program atau pun rumus dari teori-teori penunjang yang ada.

A. Web Crawling

Web Crawling adalah suatu proses di mana skrip yang dibuat bertujuan untuk melakukan scan ke halaman-halaman internet lainnya [2]. Kegunaan dari web crawling adalah untuk mendapatkan informasi yang diinginkan dari halaman-halaman internet yang dituju. Demi mencapai tujuan ini, maka dibutuhkan sebuah skrip di mana skrip tersebut dapat dengan sendirinya berjalan otomatis untuk mendapatkan informasi yang dibutuhkan tersebut [3]. Salah satu cara untuk melakukan web crawling adalah dengan melakukan parsing HTML, dimana skrip dari halaman web yang dituju akan diambil, dan dari sana akan diekstraksi informasi-informasi yang diinginkan dari halaman HTML tersebut.

Sebuah web crawler adalah bot Internet yang secara otomatis menelusuri World Wide Web, biasanya untuk tujuan pengindeksan web (web spidering) [4]. Beberapa mesin pencari web dan beberapa situs lain menggunakan web crawling untuk memperbarui konten web mereka atau indeks konten web lain. Web crawler dapat menyalin semua halaman yang dikunjungi untuk diproses kemudian oleh developer. Web crawler mengkonsumsi sumber daya pada sistem yang dikunjungi dan sering mengunjungi situs tanpa persetujuan. Web crawler dapat memvalidasi hyperlink dan kode HTML [5].

Sebuah crawler web dimulai dengan daftar URL untuk dikunjungi. Jika crawler bekerja untuk melakukan pengarsipan website itu salinan dan menyimpan informasi sebagai kelanjutannya. Arsip biasanya disimpan sedemikian rupa sehingga dapat dilihat, dibaca dan dinavigasikan karena arsip berada di web [6]. Arsip dikenal sebagai repositori dan dirancang untuk menyimpan dan mengelola koleksi halaman web. Repositori hanya menyimpan halaman HTML dan halaman ini disimpan sebagai file yang berbeda. Sebuah repositori mirip dengan sistem lain yang menyimpan data, seperti database modern. Satu-satunya perbedaan adalah bahwa repositori tidak perlu semua fungsi yang ditawarkan oleh sistem database. Repositori menyimpan versi terbaru dari halaman web diambil oleh crawler. Jumlah kemungkinan URL yang dikunjungi yang dihasilkan oleh perangkat lunak server-side juga telah membuat sulit bagi web crawler untuk menghindari mengambil duplikat konten. kombinasi tak berujung HTTP GET (berdasarkan URL) parameter yang ada, dari yang hanya pilihan kecil benar-benar akan kembali konten yang unik [7].

B. Rule-Based System

Dalam ilmu komputer, sistem rule-based digunakan sebagai cara untuk menyimpan dan memanipulasi data pengetahuan untuk menginterpretasikan informasi dalam cara yang bermanfaat [8]. Algoritma rule-based ini sering digunakan dalam aplikasi kecerdasan buatan dan penelitian. Sebuah

```

For each attribute,
  For each value of the attribute, make a rule as follows:
    count how often each class appears
    find the most frequent class
    make the rule assign that class to this attribute-value
  Calculate the error rate of the rules
  Choose the rules with the smallest error rate

```

Gambar. 1. Contoh dari algoritma Rule-Based System.

aplikasi yang menerapkan sistem rule-based memiliki sederatan aturan (rule) yang menjadi dasar dari penentuan (knowledge base) [9].

Teori ini menggunakan teknik yang sederhana, yang dimulai dengan dasar aturan yang berisi semua pengetahuan dari permasalahan yang dihadapi yang kemudian dikodekan ke dalam aturan IF-THEN dan sebuah tempat penyimpanan yang mengandung data, pernyataan dan informasi awal. Sistem akan memeriksa semua aturan kondisi (IF) yang menentukan subset, set konflik yang ada. Jika ditemukan, maka sistem akan melakukan kondisi THEN. Perulangan atau looping ini akan terus berlanjut hingga salah satu atau dua kondisi bertemu, jika aturan tidak diketemukan maka sistem tersebut harus keluar dari perulangan [10].

C. Naïve Bayes Classification

Menggunakan teorema Bayes untuk metode pengklasifikasian dengan menggunakan metode probabilitas dan statistic [11]. Memprediksi peluang di masa depan berdasarkan pengalaman di masa sebelumnya, dengan ciri utama memiliki asumsi yang sangat kuat dan memiliki independensi dari masing-masing kondisi. Naïve Bayes Classifier bekerja lebih baik dibanding model classifier lainnya dan membutuhkan jumlah data pelatihan yang kecil untuk menentukan estimasi parameter yang diperlukan dalam proses pengklasifikasian [12].

Algoritma Naïve Bayes adalah sebuah algoritma sederhana yang bekerja baik pada kategorisasi teks. Algoritma ini memanfaatkan metode probabilitas dan statistic yang dikemukakan oleh ilmuwan inggris Thomas Bayes, yaitu memprediksi probabilitas di masa depan berdasarkan pengalaman di masa sebelumnya [13]. Dasar dari teori Naïve Bayes dalam pemrograman adalah rumus berikut ini:

$$P(c|x) := \frac{P(c) * P(x|c)}{P(x)} \quad (1)$$

Di mana:

$P(x)$ adalah nilai input fitur yang digunakan

$P(c)$ adalah frekuensi kelas yang ada

$P(c|x)$ adalah nilai probabilitas input fitur yang dicari jika diketahui kelasnya

Apabila diberikan k atribut yang saling bebas, nilai probabilitas dapat diberikan sebagai berikut:

$$P(x_1, x_k|C) := P(x_k|C) * \dots * P(x_1|C) \quad (2)$$

Algoritma yang digunakan juga adalah klasifikasi Naïve Bayes, dengan rumusan:

$$c^* = \operatorname{argmax}_c P(c|x) \quad (3)$$

Algoritma ini mencari nilai maksimum dari probabilitas yang didapat dari masing-masing kelas. Nilai probabilitas yang paling maksimum adalah nilai yang paling benar untuk kelas itu.

III. METODE DAN INTI PENELITIAN

Untuk menyelesaikan penelitian ini, dilakukan proses pengembangan aplikasi dengan menggunakan metodologi BUP (Basic Unified Process), yang merupakan versi RUP (Rational Unified Process) milik IBM yang lebih simple. Dalam BUP, development bagian-bagian sistem dikembangkan dalam waktu dan kecepatan yang berbeda, dan diintegrasikan setelah bagian-bagian sistem tersebut selesai dibuat. Developer akan kembali ke bagian yang telah selesai dibuat untuk memperbaiki dan meningkatkan bagian tersebut. BUP ini memiliki tujuan untuk menangani kelemahan yang ditemukan pada waterfall model, di mana BUP sendiri memiliki kemampuan yang lebih untuk mengakomodasi perubahan selama pengembangan software karena proses kerja yang berbentuk sebuah siklus. BUP memiliki deskripsi yang lebih simple dan menuju inti dari suatu permasalahan. BUP juga menyediakan proses yang terstruktur karena memiliki syarat yang spesifik dalam masing-masing tahapan pengerjaannya.

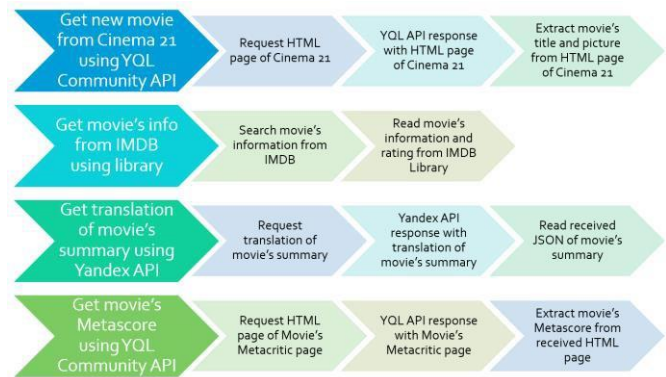
A. Proses Web-Crawling

Proses web-crawling ini merupakan proses di mana sistem akan mencari informasi dari sumber lain (website lainnya) dan menyimpan informasi-informasi tersebut ke dalam database. Sumber lain yang dimaksud adalah: website Cinema 21, IMDB, dan Metacritic. Untuk proses web-crawling ini, penulis menggunakan beberapa tools, yaitu:

- Library Curl: untuk mengirim request kepada layanan API dan membaca response JSON dari layanan API tersebut.
- Library IMDB: untuk mencari film pada IMDB dan mendapatkan informasi-informasi film pada IMDB.
- YQL Community API: untuk mendapatkan kode dari halaman web Cinema 21 dan Metacritic.
- Yandex Translation API: untuk mendapatkan terjemahan dari sinopsis film dari IMDB (yang berbahasa Inggris) ke dalam Bahasa Indonesia.

Untuk pengambilan informasi dari halaman web Cinema 21 dan Metacritic, sistem akan menggunakan metode web scraping, di mana sistem akan membaca dan memotong kode dari halaman web tersebut untuk mendapatkan informasi yang dibutuhkan. Metode ini membutuhkan layanan YQL Community API dan Library Curl, karena tanpa YQL API, Cinema 21 hanya akan menampilkan pesan error (Cookies not found). Library Curl ini juga dibutuhkan agar sistem bisa membaca pesan balasan dari YQL Community API yang berisi kode dari halaman HTML web.

Pada proses web-crawling ini sendiri, pertama-tama, sistem akan meminta kode halaman Cinema 21 kepada YQL



Gambar. 2. Proses web-crawl yang meliputi YQL Community API, IMDB Library, Yandex Translation API, dan Curl Library.

Community API, untuk kemudian mengambil judul film dan link dari poster film. YQL Community API ini diperlukan karena tanpa layanan API YQL ini, sistem hanya akan mendapatkan header dan footer dari halaman web Cinema 21.

Setelah sistem mendapatkan judul-judul film dari Cinema 21, maka sistem akan mencari informasi dari film-film tersebut dari IMDB dengan menggunakan Library IMDB. Adapun sistem hanya akan menggunakan library IMDB ini apabila judul film tersebut belum tercatat sebelumnya pada database. Setelah sistem selesai mendapatkan informasi-informasi film dari database, sistem akan meminta terjemahan dari sinopsis film kepada Yandex Translation API. Karena sinopsis film ini didapatkan dari IMDB, maka sinopsis film ini berbahasa Inggris. Tujuan pasar dari aplikasi web yang dibuat ini adalah bagi masyarakat Indonesia, dan karena itu, sinopsis dari film yang berbahasa Inggris ini harus diterjemahkan terlebih dahulu ke Bahasa Indonesia.

Apabila sistem telah menerima hasil terjemahan sinopsis film dari Yandex API, maka sistem akan kemudian mengambil Metascore dari film. Karena tidak ada layanan API atau library yang bisa digunakan untuk mengambil Metascore film, maka penulis harus mendapatkan informasi Metascore film ini dengan cara web-scraping. Sistem akan meminta kode halaman web Metacritic menggunakan YQL Community API, dan kemudian mengekstrak Metascore film dari barisan HTML web. Sama dengan proses pengambilan informasi dari IMDB sebelumnya, proses pengambilan Metascore film ini hanya akan dilakukan oleh sistem apabila judul film tersebut belum tercatat pada database.

B. Proses Pemilahan dan Penilaian Tweet

Proses pemilahan dan penilaian tweet ini merupakan langkah-langkah yang dilakukan oleh sistem demi mencapai tujuan akhir, yaitu mendapatkan sentiment dari tweet. Setiap tweet yang akan diproses akan diubah mengikuti format UTF-8, dan ditransformasikan menjadi huruf kecil seluruhnya menggunakan fungsi `strtolower()`. Proses ini terdiri dari tiga buah sub-proses, di mana ke-3 buah sub-proses itu sendiri adalah: Pre-processing data, Rule-Based System, dan Naïve Bayes Classifier. Pada proses pemilahan dan penilaian tweet ini, sistem akan menggunakan beberapa tools, yaitu:

- Sentiment Lexicon dataset, sebagai dataset

TABEL I
CONTOH PROSES PEMILAHAN DAN PENILAIAN TWEET

Input	wow filmnya #hangout bagus banget gan @radityadika gue kagum
Feature Reduction	wow filmnya HASHTAG bagus banget gan USERNAME gue kagum
Normalization	wow filmnya HASHTAG bagus sangat sahabat USERNAME saya kagum
Rule-Based	wow filmnya HASHTAG bagus sangat sahabat USERNAME saya kagum
Final Text	wow filmnya HASHTAG bagus sangat sahabat USERNAME saya kagum
Hasil Test	Review Film: Ya Sentimen: Positif

Contoh dari langkah-langkah yang dilakukan oleh sistem terhadap tweet untuk mendapatkan hasil akhir, yaitu sentimen tweet.

perbandingan pada Rule-Based sistem.

- Common Words Review dan Non-Review data, sebagai data perbandingan pada Rule-Based sistem.
- Library Sentiment Analyzer, untuk menentukan sentiment akhir dari tweet (positif/negatifnya suatu tweet).
- Movie Review Sentiment Polarity Dataset, sebagai training dataset untuk library Sentiment Analyzer [16].

Pada langkah pertama (pre-processing data), sistem akan melakukan dua buah tahapan, yaitu: Feature Reduction dan Normalization. Pada tahap Feature Reduction ini, sistem akan mengganti hashtag menjadi kata "HASTHTAG", link menjadi kata "URL", dan username menjadi kata "USERNAME". Sistem juga akan mengganti judul film menjadi "JUDULFILM", serta menghapus seluruh tanda baca. Pada tahap Normalization, sistem akan mengganti seluruh kata bukan baku dan kata singkatan yang terdapat pada tweets berdasarkan data kata singkatan yang telah disusun oleh penulis. Daftar kata singkatan dan kata bukan baku yang telah disusun oleh penulis ini terdiri dari 1991 baris.

Selanjutnya pada tahap Rule-Based System, sistem akan membandingkan tweet dengan beberapa data, yaitu: Sentiment Lexicon dataset, Common Words Review data, dan Common Words Non-Review data. Tahap Rule-Based ini sendiri digunakan oleh sistem untuk menentukan status dari tweet, apakah tweet tersebut merupakan review film atau bukan. Tiap kata/frase yang sama pada tweets ditemukan pada ke-3 data ini, akan diberi poin-poin tertentu sesuai poin dari kata/frase itu sendiri pada data tersebut.

Apabila total dari poin yang didapatkan oleh tweet tersebut berjumlah sama dengan atau lebih dari 10, maka sistem akan menilai tweet tersebut sebagai review film. Setelah itu, sistem juga akan membandingkan tweet dengan data sentiment negatif dan data sentiment positif yang umumnya ditemukan pada review film. Data sentiment positif dan negatif yang disusun ini memiliki nilai/poin yang berbeda-beda untuk masing-masing kata/frase. Tiap kata/frase yang sama pada tweet dengan masing-masing data sentiment ini, akan disimpan pada variable positivity dan negativity, untuk kemudian digunakan selanjutnya pada proses ke-3.

Pada proses ke-3, yaitu tahap Naïve Bayes Classifier, sistem akan mulai menentukan sentiment dari teks tweets [17]. Seluruh tweets yang telah ditentukan sebagai review akan masuk ke dalam proses ke-3 ini. Untuk proses ini, sistem akan

TABEL II
CONTOH HASIL PENGUJIAN

Text Akhir	Review		Sentimen	
	Sistem	Admin	Sistem	Admin
kelemahan HASHTAG karakter2nya konsep fantasinya ter develop konklusinya anti klimaks anyone lihat cerita	✓	✓	+	-
JUDULFILM puashati bagus menyesal bagus bagus bagus gila 10 10 well done	✓	X	+	-
HASHTAG furious8 oke pembahasan	✓	✓	+	+
JUDULFILM URL USERNAME USERNAME	X	X	-	-
both are good weh type spooky japanese culture	✓	✓	+	+
JUDULFILM or my neighbor totoro bagus kaget menghina cerita	✓	✓	-	-
habis lihat JUDULFILM bodoh deh lihat URL	✓	✓	-	+
sadis kejam keren john wick chapter 2 URL	✓	✓	-	-
lihat JUDUL temen2 bilang rugi lihat bioskop video playlist USERNAME	✓	✓	-	-
URL JUDULFILM 2017 full movies download	X	X	-	-
JUDULFILM aja URL	X	X	-	-

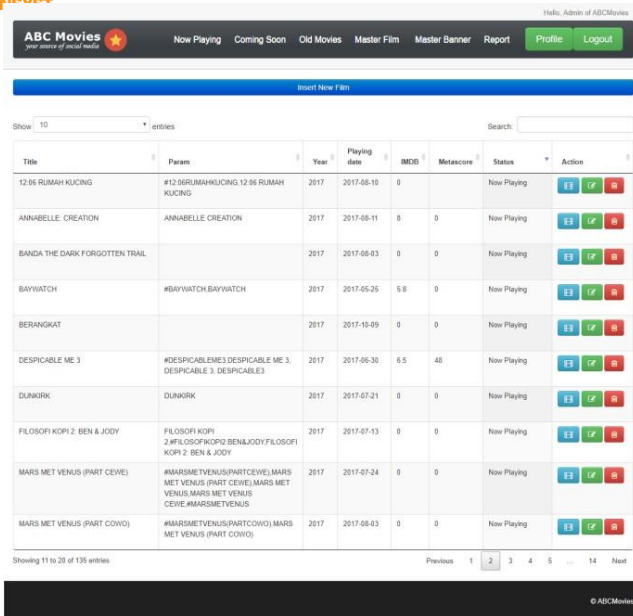
Beberapa contoh tweet yang telah mengalami proses pemilahan dan penilaian tweet serta nilai kebenaran dari tweet tersebut.

menggunakan Library Sentiment Analyzer, yang bisa memudahkan penulis dalam menggunakan algoritma Naïve Bayes. Apabila tweets telah diproses oleh library Sentiment Analyzer, sistem akan menambahkan hasil dari analisa library tersebut ke dalam variable negativity dan positivity. Apabila hasil dari variable negativity lebih besar dari positivity, maka sistem akan menilai tweets tersebut sebagai negatif, dan begitu pula sebaliknya.

IV. HASIL EKSPERIMEN DAN PENELITIAN

Data uji yang digunakan adalah beberapa judul film, seperti Beauty and The Beast, dan The Guys. Data pengujian ini (tweets) didapatkan dari Twitter dengan menggunakan Twitter Search API [18]. Data ujicoba tersebut kemudian akan diproses sesuai dengan sistem Rule-Based dan Naïve Bayes, yang kemudian hasil akhirnya (output) akan dibandingkan dengan data yang telah diklasifikasikan secara manual oleh penulis sebelumnya. Setelah uji coba selesai dilakukan, akan dilakukan penghitungan persentase kebenaran algoritma. Untuk menghitung persentase kebenaran klasifikasi data sendiri, yang dihitung tiga buah evaluasi data, yaitu: akurasi, presisi, dan recall. Apabila data FP terlalu banyak, maka nilai dari presisi algoritma akan menjadi jelek. Apabila data FN terlalu banyak, maka nilai dari recall algoritma akan menjadi jelek [19].

Akan dijabarkan mengenai uji coba yang telah dilakukan dalam rangka menguji kemampuan serta keakurasian algoritma yang diimplementasikan pada penelitian ini. Pada table 1 di atas telah diberikan hasil dari beberapa data uji yang



Gambar. 3. Contoh user interface dari web serta hasil crawling yang didapatkan dari website Cinema21, Metacritic, IMDB, dan Twitter.

telah diproses. Kolom sistem akan menunjukkan status apa yang ditentukan oleh sistem terhadap tweet tersebut (review/non-review dan positif/negatif), sedangkan kolom admin akan menunjukkan status sebenarnya dari tweet tersebut (menurut manusia).

Beberapa contoh tweets seperti pada table 1 di atas, telah mengalami pengklasifikasian tweet mana yang merupakan review film dan mana yang bukan, dengan menggunakan sistem Rule-Based. Setelah didapatkan tweet-tweet yang merupakan review, maka tweet-tweet tersebut akan diproses melalui Naïve Bayes Classification untuk menentukan sentiment dari review. Masing-masing algoritma yang digunakan (Rule-Based System dan Naïve Bayes Classifier), akan dihitung persentase kebenarannya. Untuk tiap-tiap pengujian yang akan dijelaskan berikut ini, digunakan jumlah tweet yang sama untuk tiap kali uji coba, yaitu sebanyak 6.323 tweet.

Pada pengujian Rule-Based System, dimana algoritma ini sendiri digunakan untuk menentukan apakah tweet termasuk film atau bukan, diberikan tindakan komparasi teks tweet dengan dataset lexicon dan common words. Pada tabel 1 di bawah ini dapat dilihat hasil evaluasi dari pengujian akhir terhadap Rule-Based System, di mana hasil presisi memiliki nilai akhir 82% dan recall memiliki nilai 74%. Hasil ini didapatkan dari pengujian sebanyak 4x dengan perlakuan yang berbeda-beda. Hasil akhir ini didapatkan ketika tiap common words diberi nilai untuk masing-masing kata/frase, sesuai dengan seringnya kata/frase tersebut digunakan pada tweet yang merupakan review film.

Pada pengujian Naïve Bayes Classifier, yang dimana algoritma ini digunakan untuk menentukan apakah tweet tersebut memiliki sentiment positif/negatif, diberikan tindakan komparasi teks tweet dengan common words sentiment dan juga penambahan training dataset dari Twitter sendiri. Dengan

TABEL III
EVALUASI OUTPUT PENGUJIAN

Rule-Based System			
	Klasifikasi Review	Klasifikasi Non-review	Total Tweets
Tweets Review	(TP) 1212	(FN) 780	1992
Tweets Non-review	(FP) 336	(TN) 3324	3660
Total data yang diuji			5652
Akurasi = (TP + TN) / (TP + TN + FP + FN)			80,255 %
Precision = TP / (TP + FP)			78,294 %
Recall = TN / (TN + FN)			80,994 %
F-Measure = (2 * Precision * Recall) / (Precision + Recall)			79,621 %
Naïve Bayes Classifier			
	Klasifikasi Positif	Klasifikasi Negatif	Total Tweets
Tweets Positif	(TP) 692	(FN) 95	787
Tweets Negatif	(FP) 148	(TN) 277	425
Total data yang diuji			1212
Akurasi = (TP + TN) / (TP + TN + FP + FN)			79,950 %
Precision = TP / (TP + FP)			82,381 %
Recall = TN / (TN + FN)			74,462 %
F-Measure = (2 * Precision * Recall) / (Precision + Recall)			78,222 %

Kalkulasi kebenaran terhadap algoritma Rule-Based yang menentukan review/non-review dan Naïve Bayes yang menentukan positif/negatif uji coba akhir yang memiliki nilai recall sebesar 74% dan nilai presisi sebesar 82% ini, diberikan tindakan penambahan 400 buah training dataset dari Twitter. Hasil akhir ini didapatkan pula dengan penambahan komparasi teks tweet dengan common words sentiment, dimana tiap kata/frase yang terdapat pada data common words sentiment ini memiliki nilai yang berbeda-beda, sesuai dengan nilai dari positif/negatifnya kata/frase itu sendiri dalam sebuah review film.

V. KESIMPULAN

Pada pembuatan aplikasi web ini, Rule-Based System menghasilkan hasil akurasi akhir sebesar 80,26% sedangkan Naïve Bayes Classifier menghasilkan nilai akurasi sebesar 79,95%. Pada Rule-Based System, hasil akurasi ini didapatkan karena adanya penggantian kata-kata bukan baku dan penggantian kata-kata singkatan pada tweets yang didapatkan. Faktor lainnya yang mempengaruhi adalah karena adanya data Common Words yang berisi daftar kata-kata/frase yang sering digunakan pada review film dan Common Words yang berisi daftar kata-kata/frase yang sering digunakan pada tweets yang jelas bukan merupakan review film. Data pada Common Words ini berpengaruh besar pada hasil akurasi pada Rule-Based System, karena masing-masing baris data pada Common Words mengandung nilai-nilainya sendiri berdasarkan sering/tidaknya kata tersebut digunakan pada review/non-review.

Hasil akurasi yang besar pada Naïve Bayes Classifier dipengaruhi oleh data Common Words positif dan negatif dan juga training dataset dari Twitter. Sama dengan Common Words review/non-review pada Rule-Based System, data Common Words negatif/positif ini digunakan untuk menentukan sentiment dari tweets yang juga memiliki nilai-nilai sendiri. Training dataset dari Twitter sendiri juga diperlukan, karena tanpa training dataset dari Twitter, hasil presisi dan recall akan berkurang sebanyak 4%, di mana apabila hasil presisi dan recall turun, akan mempengaruhi hasil

dari akurasi dan F-Measure pula.

DAFTAR PUSTAKA

- [1] C. Basu, H. Hirsh, W. Cohen, and others, "Recommendation as classification: Using social and content-based information in recommendation," in *Aaai/iaai*, 1998, pp. 714–720.
- [2] C. Olston, M. Najork, and others, "Foundations and Trends® in Information Retrieval," *Found. Trends® in Inf. Retr.*, vol. 4, no. 3, pp. 175–246, 2010.
- [3] C. De Groc, "Babouk: Focused web crawling for corpus compilation and automatic terminology extraction," in *2011 IEEE/WIC/ACM International Conferences on Web Intelligence and Intelligent Agent Technology*, 2011, vol. 1, pp. 497–498.
- [4] J. Rennie and A. McCallum, "Efficient web spidering with reinforcement learning," 1999.
- [5] S. C. Herring, "Web content analysis: Expanding the paradigm," in *International handbook of Internet research*, Springer, 2009, pp. 233–249.
- [6] H. W. Park and M. Thelwall, "Hyperlink analyses of the World Wide Web: A review," *J. Comput. Commun.*, vol. 8, no. 4, p. JCMC843, 2003.
- [7] S. M. Schneider and K. A. Foot, "The web as an object of study," *New media & Soc.*, vol. 6, no. 1, pp. 114–122, 2004.
- [8] J. A. Bernard, "Use of a rule-based system for process control," *IEEE Control Syst. Mag.*, vol. 8, no. 5, pp. 3–13, 1988.
- [9] E. Lembessis, "Dynamic learning behaviour of a rule-based self-organising controller.," Queen Mary, University of London, 1984.
- [10] J. Efstathiou, "Rule-based process control using fuzzy logic," in *Approximate reasoning in intelligent systems, decision and control*, Elsevier, 1987, pp. 145–158.
- [11] H. Yu and V. Hatzivassiloglou, "Towards answering opinion questions: Separating facts from opinions and identifying the polarity of opinion sentences," in *Proceedings of the 2003 conference on Empirical methods in natural language processing*, 2003, pp. 129–136.
- [12] P. D. Turney, "Thumbs up or thumbs down? Semantic orientation applied to unsupervised classification of reviews," *arXiv Prepr. cs/0212032*, 2002.
- [13] D. D. Lewis, "Representation and learning in information retrieval," University of Massachusetts Amherst, 1992.
- [14] D. D. Lewis, "Naive (Bayes) at forty: The independence assumption in information retrieval," in *European conference on machine learning*, 1998, pp. 4–15.
- [15] R. B.-R. U. P. Content, "Basic Unified Process: A Process for Small and Agile Projects."
- [16] B. Pang, L. Lee, and S. Vaithyanathan, "Thumbs up? Sentiment classification using machine learning techniques," *arXiv Prepr. cs/0205070*, 2002.
- [17] L. Dey, S. Chakraborty, A. Biswas, B. Bose, and S. Tiwari, "Sentiment analysis of review datasets using naive bayes and k-nn classifier," *arXiv Prepr. arXiv1610.09982*, 2016.
- [18] M. Mertiya and A. Singh, "Combining naive bayes and adjective analysis for sentiment detection on Twitter," in *2016 International Conference on Inventive Computation Technologies (ICICT)*, 2016, vol. 2, pp. 1–6.
- [19] L. L. Dhande and G. K. Patnaik, "Analyzing sentiment of movie review data using Naive Bayes neural classifier," *Int. J. Emerg. Trends & Technol. Comput. Sci.*, vol. 3, no. 4, pp. 313–320, 2014.

INSYST

Journal of Intelligent System and Computation

Volume 03 Nomor 01 April 2021

Author Guidelines

- Manuscript should be written in Indonesia and be submitted online via journal website. Online Submission will be charged at no Cost
- Manuscript should not exceed 15 pages including embedded figures and tables, without any appendix, and the file should be in Microsoft Office (.doc/.docx). [download template](#)
- Title, Abstract and Keywords must be written in bilingual
- Title should be less than 15 words
- Abstracts consists of no more than 200 words, contains the essence of the article and includes a brief background, objectives, methods and results or findings of the study. Abstract is written in one paragraph.
- Keywords are written in Indonesia and English three to five words/phrases, separated with coma and consist of important words/phrases from the article.
- Author's name, affiliation, affiliation address and email. State clearly and include country's name on your affiliation address.
- The main text of the writing should be consists of: Introduction, Method, Result and Discussion, and Conclusion; followed by Acknowledgment and Reference
- Introduction State adequate background, issues and objectives, avoiding a detailed literature survey or a summary of the results. Explain how you addressed the problem and clearly state the aims of your study.
- Used method is the scientific in the form of study of literature, observation, surveys, interviews, Focus Group Discussion, system testing or simulation and other techniques commonly used in the world of research. It is also recommended to describe analysis techniques used briefly and clearly, so that the reader can easily understand.
- Results should be clear, concise and not in the form of raw data. Discussion should explore the significance of the results of the work, not repeat them. Avoid extensive citations and discussion of published literature. INSYST will do the final formatting of your paper.
- Conclusion should lead the reader to important matter of the paper. Authors are allowed to include suggestion or recommendation in this section. Write conclusion, suggestion and/or recommendation in narrative form (avoid of using bulleting and numbering)
- Acknowledgments. It is highly recommended to acknowledge a person and/or organizations helping author(s) in many ways. Sponsor and financial support acknowledgments should be included in this section. Should you have lots of parties

to be acknowledged, state your acknowledgments only in one paragraph. Avoid of using bulleting and numbering in this section

- The number of references are not less than 10 with at least 8 primary references. Primary references are include journal, thesis, disertasion and all kinds of research reports. All refferences must come from source published in last 7 years.
- Figure and table should be in black and white, and if it is made in color, it should be readable when it is later printed in black and white.
- Figure and table should be clearly readable and in a proportional measure to the overall page.

Tim Redaksi

Journal of Intelligent System and Computation

Departement of Informatics

Institut Sains dan Teknologi Terpadu Surabaya

Jl. Ngagel Jaya Tengah 73-77 Surabaya

Email: insyst@istts.ac.id

Website: <https://jurnal.stts.edu/index.php/INSYST/index>