

PRAPROPOSAL PENELITIAN DISERTASI

**DETEKSI KECELAKAAN LALU LINTAS DI JALAN RAYA
DENGAN INPUT *VIDEO STREAMING* MENGGUNAKAN
METODE *SUPERVISED* DAN *REINFORCEMENT*
*LEARNING***



**I NYOMAN EDDY INDRAYANA
NIM. 2091011007**

**PROGRAM STUDI DOKTOR ILMU TEKNIK
FAKULTAS TEKNIK
UNIVERSITAS UDAYANA
2020**

PRAPROPOSAL PENELITIAN DISERTASI

**DETEKSI KECELAKAAN LALU LINTAS DI JALAN RAYA
DENGAN INPUT *VIDEO STREAMING* MENGGUNAKAN
METODE *SUPERVISED* DAN *REINFORCEMENT*
*LEARNING***



**I NYOMAN EDDY INDRAYANA
NIM. 2091011007**

**PROGRAM STUDI DOKTOR ILMU TEKNIK
FAKULTAS TEKNIK
UNIVERSITAS UDAYANA
2021**

Lembar Persetujuan Pembimbing Akademik

PRAPROPOSAL PENELITIAN DISERTASI INI TELAH DISETUJUI

PADA TANGGAL

Pembimbing Akademik

(Prof. Dr. Ir. Made Sudarma, M.A.Sc., IPU.)
NIP. 19651231 199303 1 189

Mengetahui:

Koordinator Program Studi Doktor Ilmu Teknik
Fakultas Teknik Universitas Udayana

(Prof. Ir. I Nyoman Arya Thanaya, ME, Ph.D.)
NIP. 19601108 198803 1 002

**Praprosal Penelitian Disertasi Ini Telah Disetujui dan Dinilai
oleh Panitia Penguji pada
Program Doktor Ilmu Teknik
Program Pascasarjana Universitas Udayana
Pada tanggal**

Panitia Penguji Praproposal Penelitian Disertasi:

Ketua : Prof. Dr. Ir. Made Sudarma, M.A.Sc., IPU.

Anggota : 1. Prof. Dr. I Ketut Gede Darma Putra, S.Kom., M.T.
2. Dr. Anak Agung Kompyang Oka Sudana, S.Kom., M.T.
3. Prof. Ir. Rukmi Sari Hartati, M.T., Ph.D.
4. Dr. Eng. I Putu Agung Bayupati, S.T., M.T.
5. Dr. Nyoman Gunantara, S.T., M.T.
6. Dr. I Made Sukarsa, S.T., M.T.

DAFTAR ISI

Lembar Persetujuan Pembimbing Akademik	3
Panitia Penguji Praproposal Penelitian Disertasi:.....	4
DAFTAR ISI	5
DAFTAR GAMBAR	7
DAFTAR TABEL.....	8
BAB I. PENDAHULUAN	9
1.1 Latar Belakang.....	9
1.2 Rumusan Masalah.....	13
1.3 Tujuan	13
1.4 Manfaat Penelitian	13
1.5 Batasan Masalah	14
1.6 Kebaharuan Penelitian	14
BAB II. TINJAUAN PUSTAKA	15
2.1 State Of The Art.....	15
2.2 Deteksi Objek bergerak.....	22
2.3 <i>Convolution Neural Network (CNN)</i>	23
2.4 Pustaka OpenCV.....	25
2.4 Pengenalan Objek bergerak di jalan raya.....	25
2.5 Deteksi Kecepatan dan lintasan.....	28
2.6 Pendeteksian Kecelakaan dengan deep learning	30
2.7 Metode Reinforcement Learning.....	32
2.8 Pengujian	33
BAB III. KERANGKA BERPIKIR DAN KONSEP PENELITIAN	35
3.1 Kerangka Berpikir.....	35
3.2 Konsep Penelitian	36
BAB IV. METODE PENELITIAN	38
4.1 Rancangan Penelitian.....	38
4.2 Lokasi dan Waktu Penelitian.....	45
4.3 Ruang Lingkup Penelitian.....	45

4.4 Penentuan Sumber Data	45
4.5 Variabel Penelitian.....	46
4.6 Bahan Penelitian	46
4.7 Instrumen Penelitian	46
4.8 Prosedur Penelitian	46
DAFTAR PUSTAKA	48

DAFTAR GAMBAR

Gambar 2. 1 Gambar Fishbone Deteksi Kejadian Kecelakaan	21
Gambar 2. 2 Background Subtraction.....	23
Gambar 2. 3 Arsitektur Multi Layer perceptron(Sieniutycz, 2020).....	24
Gambar 2. 4 Arsitektur Klasifikasi Objek dengan CNN	26
Gambar 2. 5 Proses Siklus Kalman Filter(Gunjal et al., 2018).....	30
Gambar 2. 6 Model Deep RL (Lu et al., 2019)	33
Gambar 3. 1 Konsep Penelitian.....	37
Gambar 4. 1 Arsitektur Pendeteksian Kejadian Kecelakaan dengan Reinforcement Learning.....	39
Gambar 4. 2 Diagram Alir Pendeteksian Objek Bergerak dengan Background Subtraction.....	40
Gambar 4. 3 Diagram Alir Klasifikasi Objek Menggunakan CNN	40
Gambar 4. 4 Diagram Alir Estimasi Kecepatan Objek Bergerak dengan Optical Flow	41
Gambar 4. 5 Diagram Alir Deteksi Lintasan dengan Kalman Filter.....	42
Gambar 4. 6 Diagram alir klasifikasi kejadian kecelakaan dengan Reinforcement Learning	43
Gambar 4. 7 Mapping Penelitian	44

DAFTAR TABEL

Tabel 2. 1 Tabel State Of The Art Penelitian	15
--	----

BAB I. PENDAHULUAN

1.1 Latar Belakang

Pada saat ini mobilitas atau perpindahan baik orang dan barang dari satu tempat ke tempat lainnya dalam satu satuan waktu, semakin tinggi, dan waktu yang di perlukan untuk berpindah semakin cepat, sehingga memerlukan moda atau alat transportasi baik di udara, darat maupun laut. Dan sebagian besar perpindahan terjadi di darat. Penggunaan kendaraan bermotor sebagai alat transportasi darat dari tahun ke tahun semakin meningkat, baik itu kendaraan roda 2 atau roda 4 maupun lebih. Selain untuk alat transportasi orang / penumpang, kendaraan juga digunakan sebagai alat angkut barang. Kondisi ini menyebabkan kasus kecelakaan menjadi hal yang sering terjadi di jalan. World Health Organization (WHO) menginformasikan bahwa kecelakaan lalu lintas merupakan salah satu penyebab utama kematian. Diperkirakan 1,35 juta orang meninggal setiap tahunnya akibat kecelakaan lalu lintas. Sekitar 20 hingga 50 juta orang mengalami cedera yang cukup serius. Berdasarkan keterangan resmi dari Kepala Biro Penerangan Masyarakat (Karo PenMas) Divisi Humas Mabes Polri Brigjen Awi Setyono, tingkat angka kecelakaan lalu lintas di negara kita masih sangat tinggi, dilaporkan bahwa peningkatan angka kecelakaan masih terjadi di minggu ke 40 Tahun 2020 ini. Dimana di minggu ke 40 tahun 2020 telah terjadi kecelakaan sebanyak 1.377 peristiwa kecelakaan (Detikcom, 2020).

Karena tingkat penggunaan alat transportasi darat lebih tinggi, sehingga kecelakaan di darat memiliki tingkat kejadian yang lebih tinggi. Kasus kecelakaan di Indonesia saat ini masih tinggi. Dan Kasus kecelakaan ini, dari tahun ke tahun tercatat terus meningkat. Tercatat 104.327 kasus terjadi di tahun 2017. Kemudian di tahun 2018 tercatat sebanyak 109.215 kasus kecelakaan yang terjadi (Statistik, 2020). Setiap kasus kecelakaan pasti menyebabkan kerugian / korban baik korban jiwa, material maupun inmaterial. Kasus kecelakaan tahun 2017 mengakibatkan 30.964 korban jiwa. Angka korban jiwa ini masih tergolong tinggi dan perlu untuk ditekan seminimum mungkin. Berdasar data yang diterima Kementerian Perhubungan dari Kepolisian, selama tahun 2016 telah terjadi kecelakaan sebanyak 106.644 kasus sehingga mengakibatkan kerugian yang diperkirakan mencapai 2,9%-3,1 % dari total PDB Indonesia. Menteri Perhubungan Budi Karya Sumadi mengatakan kecelakaan tersebut menyebabkan 31.262 meninggal dunia, 20.075 luka berat, dan 120.532 korban luka ringan, dengan total kerugian ditaksir sebesar Rp. 229M, sementara tahun 2020 sampai minggu ke 39 terjadi

kenaikan jumlah kecelakaan lalu lintas sebesar 3% jika dibandingkan dengan periode yang sama tahun lalu. Ada banyak faktor penyebab terjadi kecelakaan, baik itu karena faktor kelalaian, kondisi jalan dan juga kondisi kendaraan (Suparmanta, 2019). Kondisi kejadian atas kecelakaan sering kali terlambat di tangani sehingga menyebabkan kerugian atas kejadian tersebut semakin tinggi, Kemungkinan korban jiwa bisa bertambah, kerugian inmaterial seperti kemacetan akan bertambah parah.

Salah satu faktor yang menyebabkan dari kurang cepatnya penanganan kasus kecelakaan adalah Petugas polisi jalan raya yang tidak setiap saat (24 Jam) bertugas di jalan raya, kondisi ini sering kali terjadi saat pergantian shif jaga, dan juga kekurangan personel polisi jalan raya khususnya pada jam jam rawan kecelakaan. Polisi tidak setiap saat berada disepanjang jalan untuk mengawasi kondisi lalu lintas jalan raya. Polisi biasanya melakukan penjagaan dan mengatur lalu lintas di persimpangan jalan. Terutama persimpangan jalan yang tidak ada lampu lalu lintas. Ini ditujukan supaya lalu lintas di persimpangan jalan berjalan lancar dan tidak terjadi kemacetan. Terutama di pagi hari pada jam – jam pegawai pergi ke kantor dan siswa masuk sekolah. Begitu pula pada saat jam pulang kantor polisi siaga di tempat tempat tertentu untuk mengatur jalannya lalu lintas. Sedangkan kejadian kecelakaan dapat terjadi sewaktu waktu

Kecepatan dalam menangani kecelakaan sangat berperan penting dalam mengurangi faktor resiko meningkatnya kerugian baik material maupun immaterial. Polisi adalah salah satu komponen yang berperan penting dalam menindaklanjuti kejadian kecelakaan di jalan. Jumlah polisi yang belum ideal dan komposisi di masing-masing polda yang belum merata mengakibatkan polisi dalam melayani masyarakat indonesia masih perlu ditingkatkan. Terutama dalam kecepatan penanganan kecelakaan. Kecelakaan lalu lintas biasanya diketahui oleh pihak kepolisian lebih banyak berdasarkan laporan dari masyarakat yang menyaksikan kejadian tersebut di jalan raya. Jika tidak ada yang melapor, misalkan kecelakaan tersebut pada saat tidak ada masyarakat yang melintas, maka informasi kecelakaan akan lambat diterima atau bahkan tidak diterima oleh pihak kepolisian. Penanganan kecelakaan oleh pihak kepolisian memerlukan keakuratan mengenai kronologis suatu kejadian kecelakaan, bisa berhubungan dengan korban baik berupa orang, benda dan lainnya. Rekayasa ulang kronologi kecelakaan juga memerlukan informasi yang akurat mengenai posisi dan kondisi sekitar sebelum kecelakaan. Inilah menjadi permasalahan lain yang memperlambat penanganan pasca kecelakaan, dimana pihak kepolisian dan pihak terkait memerlukan informasi yang cepat dan akurat atas kronologis kejadian kecelakaan tersebut, dalam menentukan mana pelaku dan korban.

Dalam era otomatisasi dan digitalisasi, kecepatan akan penerimaan data dan informasi mengenai kasus / kejadian kecelakaan di jalan raya sangat memungkinkan untuk ditingkatkan. Ada banyak teknologi yang mendukung hal tersebut. Salah satunya adalah teknologi dengan

menggunakan computer vision. *Computer vision* merupakan bidang teknologi informasi yang menganalisa (Parsa *et al.*, 2019), memperoleh atau mendeteksi, mengolah dan memahami (Darma Putra *et al.*, 2020b) data visual seperti gambar dan video. *Computer vision* meniru kemampuan panca indera manusia yaitu mata sebagai alat untuk menerima input informasi di sekeliling kita. Teknologi *computer vision* menerima input berupa gambar atau citra melalui kamera yang kemudian diolah oleh *control processing unit* (CPU). Data video juga dapat diterima dengan teknologi *computer vision*, dimana sebelum diolah oleh CPU, data video ini dipecah terlebih dahulu menjadi frame-frame gambar.

Teknologi computer vision memiliki banyak cabang dan banyak sekali dimanfaatkan untuk mendeteksi, mengenali dan menganalisa objek dalam suatu gambar. Salah satu pemanfaatannya dapat digunakan dalam mendeteksi kecelakaan lalu lintas. Setelah menentukan frame yang mana terdapat kejadian kecelakaan lalu lintas, selanjutnya dapat digunakan untuk membuat sketsa atau kronologis kecelakaan yang terjadi. Metode *convolution neural network* dapat digunakan sebagai solusi dalam menyelesaikan masalah ini. Metode CNN ini merupakan salah satu metode *machine learning* (Vieira *et al.*, 2020) yang banyak digunakan saat ini. Metode ini adalah pengembangan dari *Multi Layer Perceptron* (MLP) yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* (Khaghani, 2020) karena dalamnya tingkat jaringan dan banyak diimplementasikan dalam data citra.

Proses pendeteksian kecelakaan yang diajukan dalam proposal penelitian ini menggunakan beberapa tahapan proses. Proses pendeteksian menggunakan sumber input utama berupa *video streaming* yang direkam melalui perangkat CCTV di jalan raya. Syarat utama dari penelitian ini adalah terpasangnya perangkat CCTV di sepanjang jalan raya untuk merekam kejadian. Rekaman kejadian ini berupa kumpulan frame-frame gambar yang berurutan sesuai dengan urutan waktu. Proses pendeteksian kejadian kecelakaan secara real time ini diawali dengan mengenali frame gambar sebagai gambar kecelakaan lalu lintas di jalan raya (Gupta and Choudhary, 2019). Kecelakaan berupa tabrakan dapat diidentifikasi adanya benturan (*collision*) (Pavithra R., 2018) pinggiran antar objek yang bergerak. Proses pengenalan kejadian kecelakaan lalu lintas dapat dilakukan dengan metode CNN (Ghosh *et al.*, 2019) (Huang *et al.*, 2020). Sistem akan di-*training* terlebih dahulu dengan dataset tentang gambar gambar kecelakaan lalu lintas (Ravindran *et al.*, 2016) yang pernah terjadi. Setelah dilakukan training terhadap sistem, kemudian diujikan ke kondisi real (Ozbayoglu *et al.*, 2016). Kemudian untuk menguatkan bahwa gambar tersebut merupakan kejadian secara real time, dilakukan kalkulasi terhadap parameter kecepatan objek dan perpotongan lintasan objek yang terlibat kecelakaan. Kalkulasi kecepatan dan lintasan objek dilakukan dengan mengambil beberapa gambar sebelum gambar tersebut dikenali sebagai kejadian kecelakaan. Penelitian ini juga melakukan pengenalan

terhadap objek apa saja yang bergerak di jalan raya. Hal ini dilakukan untuk mengetahui objek apa saja yang terlibat kecelakaan. Apakah objek tersebut mobil, sepeda motor, pejalan kaki ataukah hewan. Pengenalan objek diawali dengan pendeteksian objek (Nguyen The and Shashev, 2018) yang bergerak di jalan raya (Putri, 2016). Setelah mendapatkan objek objek tersebut, dilakukan proses labeling dan dibuat batas pinggiran objek (*boundary object*). Berikutnya dilanjutkan dengan proses klasifikasi dan pengenalan objek. Proses klasifikasi dan pengenalan objek menggunakan metode *Convolution Neural Network* (CNN) (Ijjina *et al.*, 2019) . Pada proses klasifikasi dan pengenalan objek ini dilakukan tahap pra proses untuk membuat model (Shah *et al.*, 2019) dari objek yang bergerak di jalan raya. Hasil dari proses klasifikasi (Fadlia and Kosasih, 2019) dan pengenalan objek ini adalah sistem dapat mengenali objek yang bergerak tersebut apakah kendaraan (Chen *et al.*, 2018) (Limantoro *et al.*, 2018), manusia (Kim *et al.*, 2020) (AlDahoul *et al.*, 2018), hewan, ataukah objek bergerak selain ketiga klasifikasi di atas. Proses selanjutnya adalah pendeteksian kecepatan dari masing, masing objek yang bergerak tersebut (Lee, 2011). Pendeteksian kecepatan (Andrew *et al.*, 2017) ini dipergunakan untuk parameter pada saat proses pendeteksian kejadian kecelakaan pada tahapan proses selanjutnya. Setelah mendeteksi kecepatan objek yang bergerak, dilakukan proses *tracking* terhadap jalur dari objek yang bergerak di jalan raya. Tracking jalur objek ini akan digunakan untuk mendeteksi adanya jalur yang bersilangan (*cross line*) untuk memastikan terjadinya perpotongan jalur antara dua atau lebih benda yang bergerak.

Dalam penelitian ini diusulkan penggunaan metode *reinforcement learning* (Collins, 2018), dimana sampai saat belum ada diterapkan pada pendeteksian kecelakaan lalu lintas. Penelitian sebelumnya masih sedikit menggunakan kejadian kecelakaan lalu lintas sebagai objek penelitian. Khususnya pendeteksian kejadian kecelakaan secara real time. Sampai saat ini lebih banyak pendeteksian dalam komputer vision menggunakan suatu benda tertentu sebagai objek penelitiannya seperti deteksi kendaraan (Lazaro *et al.*, 2017), pejalan kaki (Kim *et al.*, 2020), hewan, deteksi wajah (Astawa *et al.*, 2020) atau benda tertentu lainnya. Objek kejadian masih sedikit digunakan sebagai objek penelitian. Penelitian sebelumnya lebih banyak menggunakan *supervised learning* seperti CNN (Bortnikov *et al.*, 2020) (Chang *et al.*, 2019a) (Ghosh *et al.*, 2019) (Gupta and Choudhary, 2019) dan SVM (Herman *et al.*, 2014) (Chen *et al.*, 2009) (Li *et al.*, 2012) (Yuan and Cheu, 2003). Metode pendeteksian kejadian kecelakaan menggunakan *reinforcement learning* ini akan menghasilkan luaran berupa penentuan keputusan secara real time apakah video streaming yang diproses adalah kejadian kecelakaan pada saat itu ataukah tidak. Luaran lainnya yang akan dihasilkan dalam penelitian ini yaitu membuat kronologi kejadian kecelakaan (Kepolisian, 2013) dari video tersebut. Luaran berupa kronologi kecelakaan ini merupakan suatu hal yang baru yang belum dihasilkan dari penelitian-

penelitian pendeteksian kecelakaan sebelumnya. Pendeteksian kejadian kecelakaan ini, diperlukan pengenalan/klasifikasi terhadap objek yang bergerak. Pada tahap klasifikasi objek akan menggunakan *supervised learning*. Secara teori metode *reinforcement learning* lebih cenderung dipergunakan dalam hal pengambilan keputusan sedangkan supervised learning lebih dipergunakan dalam hal pengklasifikasian (Huang *et al.*, 2020). Sehingga keseluruhan tahapan penelitian ini menggunakan *supervised learning* (pengklasifikasian objek) dan *reinforcement learning* (pengambilan keputusan kejadian kecelakaan). *Reinforcement learning* akan menambah data pengetahuan dari sistem, seiring berjalannya waktu testing di lapangan. Harapannya semakin banyak data baru hasil testing yang digunakan untuk membangun model pengenalan kecelakaan lalu lintas, maka keputusan sistem akan lebih akurat (Astawa *et al.*, 2020).

1.2 Rumusan Masalah

Dari uraian latar belakang di atas dapat dirumuskan beberapa rumusan masalah dalam penelitian ini yaitu :

1. Bagaimana mendeteksi kejadian kecelakaan di jalan raya dengan input video streaming menggunakan metode *Reinforcement Learning*.
2. Sejauh mana peningkatan akurasi *reinforcement learning* dibandingkan penggunaan metode *supervised learning* pada pendeteksian kejadian kecelakaan.
3. Bagaimana membuat kronologis kejadian kecelakaan di jalan raya secara otomatis dari input *video streaming*.

1.3 Tujuan

Adapun tujuan dari penelitian ini adalah :

1. Membangun suatu perangkat lunak yang dapat mendeteksi kejadian kecelakaan dengan input *video streaming*.
2. Mengetahui tingkat akurasi *reinforcement learning* dibandingkan penggunaan metode *supervised learning* pada pendeteksian kejadian kecelakaan.
3. Membuat kronologis kejadian kecelakaan di jalan raya secara otomatis dari input *video streaming*.

1.4 Manfaat Penelitian

Adapun manfaat yang diharapkan dalam penelitian pendeteksian kecelakaan di jalan raya ini antara lain :

1. Manfaat akademisi, dengan metode-metode yang digunakan dalam penelitian ini diharapkan dapat menjadi referensi dalam melakukan penelitian lebih lanjut terutama dalam pendeteksian kecelakaan di jalan raya menggunakan input *video streaming*.
2. Manfaat praktis, diharapkan penelitian pendeteksian kecelakaan di jalan raya menggunakan input *video streaming* ini memberikan kontribusi dalam:
 - a. mempercepat tersampainya informasi kecelakaan ke pihak polisi dan petugas medis yang menangani kecelakaan lalu lintas.
 - b. membantu mempercepat tugas polisi dalam membuat sketsa kejadian kecelakaan di jalan raya.

1.5 Batasan Masalah

Batasan permasalahan dalam penelitian pendeteksian kecelakaan di jalan raya ini antara lain:

1. Pendeteksian kejadian hanya terbatas pada kejadian kecelakaan lalu lintas di jalan raya
2. Input *video streaming* yang diproses adalah input video di siang hari.
3. Kejadian kecelakaan lalu lintas yang dideteksi hanya terbatas kecelakaan antara kendaraan dengan kendaraan, kendaraan dengan manusia dan kendaraan dengan hewan.

1.6 Kebaharuan Penelitian

Dalam penelitian ini digunakan metode *Reinforcement Learning* (yang selanjutnya disingkat RL) dalam pendeteksian kejadian kecelakaan lalu lintas di jalan raya. Penelitian ini juga menggunakan metode *supervised learning* dalam pengklasifikasian objek bergerak di jalan raya yang hasilnya digunakan sebagai parameter pendukung keputusan kejadian kecelakaan secara real time. *Supervised learning* dengan menggunakan Metode CNN juga digunakan untuk *training sistem* kejadian-kejadian kecelakaan yang sudah terjadi. Sampai saat ini belum ada yang menggunakan RL dalam pendeteksian kecelakaan lalu lintas di jalan raya secara real time. Disamping itu pada penelitian ini memberikan kontribusi kepada pihak kepolisian dalam membuat kronologi kecelakaan secara otomatis dari sistem berupa objek yang terlibat, kecepatan objek, arah atau lintasan objek yang dilalui serta garis batas objek yang terlibat kecelakaan.

BAB II. TINJAUAN PUSTAKA

2.1 State Of The Art

Penelitian pendeteksian kejadian kecelakaan di jalan raya menggunakan metode RL ini didasarkan atas beberapa penelitian sebelumnya Adapun penelitian penelitian tersebut adalah

Tabel 2. 1 Tabel State Of The Art Penelitian

No	Penulis dan Tahun	Judul Penelitian	Metode Yang digunakan
1	Tian, D., Zhang, C., Duan, X. and Wang, X. 2019	An Automatic Car Accident Detection Method Based on Cooperative Vehicle Infrastructure Systems	Cooperative Vehicle Infrastructure Systems (CVIS) yang didalamnya menggunakan algoritma <i>deep learning CNN</i>
2	Wang, C., Dai, Y., Zhou, W. and Geng, Y, 2020	A Vision-Based Video Crash Detection Framework for Mixed Traffic Flow Environment Considering Low-Visibility Condition. Journal of Advanced Transportation	Retinex untuk perbaikan citra, Frame Work Yolo3 untuk klasifikasi objek
3	Huang, T., Wang, S. and Sharma, A. 2020	Highway crash detection and risk estimation using deep learning	Convolution Neural Network (CNN)
4	Ravindran, V., Viswanathan, L. and Rangaswamy, S. 2016	A Novel Approach to Automatic Road-Accident Detection using Machine Vision Techniques	SVM(Support Vector Mechine)
5	Chen, Y., Yu, Y. and Li, T. 2016	A vision based traffic accident detection method using extreme learning machine	extreme learning machine
6	Chen, L., Ye, F., Ruan, Y., Fan, H. and Chen, Q. 2018	An algorithm for highway vehicle detection based on convolutional neural network	Convolution Neural Network (CNN)
7	Lin, Y., Li, L., Jing, H., Ran, B. and Sun, D. 2020	Automated traffic incident detection with a smaller dataset based on generative adversarial networks	generative adversarial networks (GAN).
8	Thakur, D. and Kaur, R. 2019	An Optimized CNN based Real World Anomaly Detection in Surveillance Videos	Convolution Neural Network (CNN)
9	Chang, W.-J., Chen, L.-B. and Su, K.-Y. 2019	DeepCrash: A Deep Learning-Based Internet of Vehicles System	Convolution Neural Network (CNN)

No	Penulis dan Tahun	Judul Penelitian	Metode Yang digunakan
		for Head-On and Single-Vehicle Accident Detection With Emergency Notification	
10	Yu, Y., Xu, M. and Gu, J. 2019	Vision-based traffic accident detection using sparse spatio-temporal features and weighted extreme learning machine	sparse spatio-temporal features and weighted extreme learning machine
11	Shah, A.P., Lamare, J.-B., Nguyen-Anh, T. and Hauptmann, A. 2018	CADP: A Novel Dataset for CCTV Traffic Camera based Accident Analysis	Context Mining (CM) dan R-CNN
12	Ijjina, E.P., Chand, D., Gupta, S. and Goutham, K. 2019	Computer Vision-based Accident Detection in Traffic Surveillance	Convolution Neural Network (CNN)
13	Lee, I.J. 2011	An accident detection system on highway using vehicle tracking trace	Background Subtraction (deteksi kendaraan bergerak)
14	Yao, Y., Xu, M., Wang, Y., Crandall, D.J. dan Atkins, E.M. 2019	Unsupervised Traffic Accident Detection in First-Person Videos	Unsupervised mechine learning <i>Future Object Localization (FOL)</i>
15	Harahap, M., Elfrida, J., Agusman, P., Rafael, M., Abram, R. dan Andrianto, K. 2019	Sistem Cerdas Pemantauan Arus Lalu Lintas Dengan YOLO (You Only Look Once v3).	YOLO -CNN
16	Akula, A., Khanna, N., Ghosh, R., Kumar, S., Das, A. dan Sardana, H.K. 2014	Adaptive contour-based statistical background subtraction method for moving target detection in infrared video sequences	Background Subtraction (deteksi Objek)
17	Putri, N.N. 2016	Aplikasi Pendeteksi Objek bergerak pada Image Sequence Dengan Metode Background Subtraction	Background Subtraction
18	Sengar, S.S. and Mukhopadhyay, S. 2020	Moving object detection using statistical background subtraction in wavelet compressed domain	Background Subtraction
19	Garcia-Garcia, B., Bouwmans, T. dan Rosales Silva, A.J. 2020	Background subtraction in real applications: Challenges, current models and future directions	Background Subtraction
20	Surendar, E., Thomas, V.M. and Posonia, A.M. 2016	Animal tracking using background subtraction on multi threshold segmentation	Background Subtraction
21	Lu, X., Xu, C., Wang, L. and Teng, L. 2018	Improved background subtraction method for detecting moving objects based on GMM	Background Subtraction
22	Yazdi, M. and Bouwmans, T. 2018	New trends on moving object detection in video images captured by a moving camera: A survey	Background Subtraction
23	Chen, L., Ye, F., Ruan,	An algorithm for highway vehicle	Faster R-CNN

No	Penulis dan Tahun	Judul Penelitian	Metode Yang digunakan
	Y., Fan, H. and Chen, Q. 2018	detection based on convolutional neural network. Eurasip Journal on Image and Video Processing	
24	Xi, X., Yu, Z., Zhan, Z., Yin, Y. and Tian, C. 2019	Multi-Task Cost-Sensitive-Convolutional Neural Network for Car Detection	MTCS-CNN
25	Arinaldi, A., Pradana, J.A. and Gurusinga, A.A. 2018	Multiple Car Detection, Recognition and Tracking in Traffic	CNN
26	Limantoro, S.E., Kristian, Y. and Purwanto, D.D. 2018	Pemanfaatan Deep Learning pada Video Dash Cam untuk Deteksi Pengendara Sepeda Motor	CNN
27	AlDahoul, N., Md Sabri, A.Q. and Mansoor, A.M. 2018	Real-Time Human Detection for Aerial Captured Video Sequences via Deep Models	CNN
28	Gao, H., Cheng, B., Wang, J., Li, K., Zhao, J. and Li, D. 2018	Object Classification Using CNN-Based Fusion of Vision and LIDAR in Autonomous Vehicle Environment	CNN
29	Doyle, D.D., Jennings, A.L. and Black, J.T. 2014	Optical flow background estimation for real-time pan/tilt camera object tracking	Optical Flow
30	Qimin, X., Xu, L., Mingming, W., Bin, L. and Xianghui, S. 2014	A methodology of vehicle speed estimation based on optical flow	Optical Flow
31	Crestani, F., Pipa, D. and Carnieri., A. 2015	Vehicle Speed Estimation Using Optical Flow	Optical Flow
32	Hua, S., Kapoor, M. and Anastasiu, D.C. 2018	Vehicle Tracking and Speed Estimation from Traffic Videos	Optical Flow
33	Gerat, J., Sopiak, D., Oravec, M. and Pavlovicova, J. 2017	Vehicle speed detection from camera stream using image processing methods	Optical Flow
34	Katsuki, T., Morimura, T. and Inoue, M. 2017	Traffic Velocity Estimation From Vehicle Count Sequences	Optical Flow
35	Liu, K., Ye, Y., Li, X. and Li, Y. 2018	A Real-Time Method to Estimate Speed of Object Based on Object Detection and Optical Flow Calculation	Optical Flow
36	Fahriannur, A., Mardiyanto, R. and Siswanto, M. 2018	Sistem Pelacakan Objek Menggunakan Kombinasi Algoritma Optical Flow dan Template Matching	Optical Flow dan Template Matching
37	Li, X. 2010	Object tracking using an adaptive Kalman filter combined with mean shift	Kalman Filter
38	Xu, S. and Chang, A. 2011	Robust Object Tracking Using Kalman Filters with Dynamic Covariance	Kalman Filter


No	Penulis dan Tahun	Judul Penelitian	Metode Yang digunakan
39	Taylor, L.E., Mirdanies, M. and Saputra, R.P. 2016	Optimized object tracking technique using Kalman filter	Kalman Filter
40	Soleh, M., Jati, G. and Hilman, M.H. 2018	MULTI OBJECT DETECTION AND TRACKING USING OPTICAL FLOW DENSITY – HUNGARIAN KALMAN FILTER (OFD - HKF) ALGORITHM FOR VEHICLE COUNTING	Kalman Filter dan optical flow
41	Delforouzi, A., Pamarthi, B. and Grzegorzec, M. 2018	Training-Based Methods for Comparison of Object Detection Methods for Visual Object Tracking. Sensors	Kalman Filter
42	Gunjal, P.R., Gunjal, B.R., Shinde, H.A., Vanam, S.M. and Aher, S.S. 2018	Moving Object Tracking Using Kalman Filter	Kalman Filter
43	Ghosh, S., Sunny, S.J. and Roney, R. 2019	Accident Detection Using Convolutional Neural Networks	CNN
44	Jang, B., Kim, M., Harerimana, G. and Kim, J.W. 2019	Q-Learning Algorithms: A Comprehensive Classification and Applications	Q-Learning
45	Sun, L. and Gong, Y. 2019	Active Learning for Image Classification: A Deep Reinforcement Learning Approach	Q-Learning
46	Bernstein, A. V. and Burnaev, E. V. 2018	Reinforcement learning in computer vision	Q-Learning
47	Gherega, A., Udrea, R.M. and Rădulescu, M. 2012	A Q-learning approach to decision problems in image processing	Q-Learning
48	Wang, C., Dai, Y., Zhou, W. and Geng, Y. 2020	A Vision-Based Video Crash Detection Framework for Mixed Traffic Flow Environment Considering Low-Visibility Condition	Yolo-CNN
49	Fang, W., Pang, L. and Yi, W. 2020.	Fang, W., Pang, L. and Yi, W. 2020.	Q-Learning, Sarsa
50	Henderson, P. and Ferrari, V. 2017	End-to-End Training of Object Class Detectors for Mean Average Precision	Mean Average Precision(mAP)
51	Chauhan, M.S., Singh, A., Khemka, M., Prateek, A. and Sen, R. 2019	Embedded CNN based vehicle classification and counting in non-laned road traffic	mAP
52	Ramcharan, A., McCloskey, P., Baranowski, K.,	A Mobile-Based Deep Learning Model for Cassava Disease Diagnosis	mAP

No	Penulis dan Tahun	Judul Penelitian	Metode Yang digunakan
	Mbilinyi, N., Mrisho, L., Ndalawa, M., Legg, J. and Hughes, D.P. 2019		
53	Mao, H., Yang, X. and Dally, B. 2019	A Delay Metric for Video Object Detection: What Average Precision Fails to Tell	mAP
54	Kulik, S. and Shtanko, A. 2020	Using convolutional neural networks for recognition of objects varied in appearance in computer vision for intellectual robots	mAP
55	Kumar, A. and Srivastava, S. 2020	Object Detection System Based on Convolution Neural Networks Using Single Shot Multi-Box Detector	mAP
56	I Nyoman Eddy Indrayana, 2021	Deteksi Kecelakaan Lalu Lintas Di Jalan Raya Dengan Input Video Streaming Menggunakan Metode Supervised dan Reinforcement Learning	Background Subtraction, CNN , Optical Flow, Kalman Filter dan Q-Learning

Pada Tabel 2.1, penelitian yang sudah pernah dilakukan lebih banyak menggunakan metode *deep learning* seperti algoritma SVM, CNN, R-CNN dan YOLO (didalamnya menggunakan CNN). Deep Learning secara umum menggunakan tahapan yang diawali dengan *praprocessing* yaitu pembuatan model. Model ini kemudian ditesting pada kondisi nyata, dan sistem mengambil keputusan berdasarkan model yang sudah dibuat.

Sedangkan pada penelitian ini diajukan suatu model pembelajaran yang menggabungkan *Supervised Learning* dengan *Reinforcement Learning* (RL). RL ini merupakan bagian dari *machine learning* yang berkaitan dengan bagaimana sistem cerdas mengambil tindakan untuk memutuskan sesuatu dari interaksi dengan lingkungannya. Pengambilan keputusan didasarkan atas memaksimalkan reward yang diberikan ke sistem. Metode RL merupakan salah satu paradigma *Machine Learning* disamping *Supervised Learning* dan *Unsupervised Learning*. Dalam teori pembelajaran, dikatakan semakin sering sistem itu dilatih dan semakin banyak dataset yang dijadikan sebagai model (Hendrayana *et al.*, 2017), akan meningkatkan akurasi dalam mengambil keputusan. Pada penelitian ini akan dibagi menjadi beberapa bagian yang dapat dilihat pada diagram fishbone Gambar 2.1. Pada Gambar 2.1 terdapat bagian objek, pra proses, metode, parameter dan pengukuran. Penelitian ini menggunakan kejadian kecelakaan sebagai objek penelitian, dimana didalamnya terdapat proses pendeteksian kendaraan, orang dan hewan. Bagian pra proses dilakukan proses deteksi objek bergerak, gray scale, *image boundary* dan proses *cropping*. Bagian metode terdapat metode-metode yang digunakan yaitu *Background*

Subtraction, optical flow, kalman filter, CNN, Yolo dan *Q-Learning*. Bagian parameter terdapat parameter-parameter yang diamati dan digunakan dalam menentukan keputusan sistem yaitu kecepatan, lintasan objek dan *fitur map* kejadian kecelakaan. Bagian pengukuran memuat pengukuran terhadap kinerja sistem yang meliputi pengukuran akurasi, presisi, *recall* dan *mean average precision (mAP)*. Disamping itu dalam penelitian ini juga akan memberikan informasi bantuan kepada pihak kepolisian mengenai informasi kronologis awal kejadian kecelakaan seperti klasifikasi objek yang terlibat kecelakaan, kecepatan objek yang terlibat dan arah atau lintasan yang dilalui beberapa saat sebelum terjadinya kecelakaan.




Gambar 2. 1 Gambar Fishbone Deteksi Kejadian Kecelakaan

2.2 Deteksi Objek bergerak

Pendeteksian kecelakaan dengan menggunakan input kamera, sudah dimulai sejak lama. Pendeteksian kecelakaan diawali dengan pendeteksian objek yang bergerak di jalan raya. Objek tersebut dapat berupa mobil, sepeda motor, pejalan kaki ataupun hewan. Tahun 2011, Lee melakukan pendeteksian terhadap kendaraan yang bergerak di jalan raya dengan menggunakan Metode *Background Subtraction* dan mendeteksi jejak lintasan kendaraan yang melintas (Lee, 2011). Metode *Background Subtraction* memang banyak digunakan untuk mendeteksi objek bergerak karena proses pendeteksian nya lebih cepat (Yazdi and Bouwmans, 2018) (Kumar and Yadav, 2016). Metode *Background Subtraction* sangat efisien digunakan karena dalam metode ini proses komputasi yang dilakukan relatif sedikit. Pada malam hari metode ini dapat juga digunakan untuk mendeteksi kendaraan yang bergerak dengan mendeteksi cahaya lampu dari kendaraan. Namun harus ditambahkan pra proses untuk mengurangi refleksi dari cahaya lampu kendaraan untuk mendapatkan sumber input gambar yang baik.

Penelitian Sumshmita juga menggunakan *Background Subtraction*. Langkah awal dalam penelitian ini adalah data video diambil sebagai input sistem yang selanjutnya diubah menjadi sejumlah frame. Kemudian dilakukan pra proses dengan menggunakan metode citra grey scale untuk memperbaiki warna citra RGB. Metode *Background Subtraction* digunakan untuk mendapatkan gambar latar depan. Dengan menggunakan analisis blob, region dan area gambar diidentifikasi dalam objek yang jelas, sehingga *noise* dapat dihilangkan di latar belakang objek (Sushmitha *et al.*, 2020). Lokasi benda bergerak dilakukan melalui pelacakan. Objek target selanjutnya diperoleh dengan bingkai video yang berurutan. Objek yang diidentifikasi sebagai mobil selanjutnya diberi bingkai. Untuk mendeteksi adanya gerakan perlu dipisahkan antara objek yang bergerak dan objek yang diam. Objek yang diam adalah latar atau background dari suatu frame image. Pepohonan, bangunan, manusia, tiang lampu, dan permukaan jalan merupakan bagian dari *background*. Dengan memisahkan latar dari frame image, diperoleh objek yang bergerak atau *foreground*. *Background* model diperoleh dengan cara mendapatkan nilai tengah dari semua frame image yang ada (Putri, 2016). Nilai tengah didapatkan dengan menggunakan fungsi median yang merupakan salah satu fungsi pada Matlab untuk pengoperasian matriks. Hasil dari penelitian ini adalah objek yang bergerak diberi tanda *bounding box* berupa segiempat panjang. Pada kondisi tertentu *Background Subtraction* dikombinasikan dengan deteksi countur (Akula *et al.*, 2014) untuk mengurangi noise pada saat memisahkan *foreground* dan *background* gambar. *Multi threshold segmentation* (Surendar *et al.*, 2016) juga dapat ditambahkan pada algoritma *Background Subtraction* untuk mempertajam

image dari objek yang bergerak. Ilustrasi Metode *Background Subtraction* dapat dilihat pada Gambar 2.1 (Mangalraj *et al.*, 2019).



Gambar 2. 2 *Background Subtraction*

Dari ilustrasi Gambar 2.1 maka diperoleh persamaan berikut :

$$B(x, y, t) = I(x, y, t - 1) \quad (1)$$

$$|I(x, y, t) - I(x, y, t - 1)| > th \quad (2)$$


dengan th adalah nilai *threshold* yang digunakan untuk menentukan *background* dan *foreground* gambar.

2.3 *Convolution Neural Network (CNN)*

Metode CNN saat ini merupakan salah satu metode deep learning (Darma Putra *et al.*, 2020a) (Sudana *et al.*, 2020) (Rokhana *et al.*, 2019) yang memiliki hasil paling signifikan dalam proses pengenalan citra, Hal ini disebabkan karena CNN dalam aktivitasnya berusaha menirukan system pengenalan citra yang terdapat pada indra penglihatan manusia, dimana hal ini menyebabkan CNN memiliki kemampuan untuk mengolah informasi citra. CNN merupakan pengembangan dari *Multi Layer Perception* (MPL), dimana MPL ini dirancang untuk mengolah data dua dimensi. CNN juga dimasukkan kedalam jenis *Deep Neural Network*, hal ini dikarenakan CNN memiliki kedalaman jaringan yang tinggi serta banyak diaplikasikan dalam data citra. Metode CNN ini berhasil mengalahkan Metode *Machine Learning* lainnya seperti misalnya SVM untuk kasus klasifikasi objek pada citra.

Metode CNN memiliki cara kerja yang sama dengan MLP, akan tetapi ada perbedaan mendasar, dimana pada metode CNN di setiap neuron dipresentasikan di dalam bentuk dua

dimensi, tidak seperti dalam MLP setiap neuron dipresentasikan hanya dalam bentuk satu dimensi. MLP adalah bagian dari *feed forward neural network* (Alsmadi *et al.*, 2009). MLP memiliki tiga jenis lapisan yaitu lapisan input, lapisan tersembunyi dan lapisan output (Gajić *et al.*, 2020) (Seiffert, 2001) (A. Dawwd and M. AL Layla, 2015).



Gambar 2. 3 Arsitektur Multi Layer perceptron(Sieniutycz, 2020)

Mengacu pada Metode *Feed Forward*, proses input dalam MLP akan dimulai dari lapisan inputan kemudian mengalir ke lapisan tersembunyi menuju lapisan keluaran (dari depan ke belakang). Lapisan tersembunyi dapat terdiri dari beberapa lapisan sesuatu dengan kebutuhan. MLP ini mengadopsi proses pembelajaran jaringan saraf biologis manusia, walaupun tidak sama persis. MLP menggunakan metode *backpropagation* dalam proses pembelajarannya. Inti dari *backpropagation* adalah meminimalisasi error yang terjadi. *Error* yang dimaksud adalah selisih nilai keluaran dari MLP dengan nilai keluaran yang diinginkan. Dengan kata lain nilai error ini digunakan untuk mengoreksi bobot dari lapisan luaran ke lapisan tersembunyi, kemudian error dipropagasi ke layer layer sebelumnya. Pada CNN, hasil proses input yang sudah dipropagasi dalam jaringan adalah data dalam bentuk dua dimensi.

2.4 Pustaka OpenCV


OpenCV merupakan kumpulan pustaka-pustaka yang bersifat open source. Pustaka ini dikembangkan oleh Intel untuk memudahkan programmer dalam membuat perangkat lunak khususnya yang berhubungan dengan citra digital (Zelinsky, 2009)(Reinius, 2013). OpenCV menyediakan berbagai algoritma yang berhubungan dengan *computer vision*. Beberapa fitur opencv yang sering digunakan adalah deteksi objek , pengenalan wajah, *kalman filter*, *support vector machine* dan banyak lagi yang terkait dengan kecerdasan buatan. OpenCV dirancang untuk pengembangan aplikasi secara real-time (Sugano and Miyamoto, 2010), memiliki sub program- sub program untuk memproses data gambar dan data video (Reinius, 2013) (Poda and Qirici, 2018) (Zelinsky, 2009). Beberapa fitur yang dimiliki oleh pustaka OpenCV adalah (1)Manipulasi data citra, (2) dasar pengolahan data citra (deteksi tepi , *filtering*, *image pyramid*, *corner detection*, konversi warna, operasi morfologi, *histogram equalization* ,sampling dan interpolasi), (3) Analisis gerakan (*segmentasi*, *optical flow*, dan *tracking*) . (4) *Image Recognition* (Reinius, 2013).

2.4 Pengenalan Objek bergerak di jalan raya

Pengenalan objek bergerak merupakan proses yang tidak dapat dipisahkan dalam tahapan pendeteksian kejadian kecelakaan di jalan raya. Pengenalan objek yang bergerak ini bertujuan untuk mengidentifikasi apakah objek yang terlibat kecelakaan nanti adalah kendaraan (mobil, sepeda motor), pejalan kaki ataupun hewan. Karena objek-objek yang disebutkan tadi ada kemungkinan penyebab dari kecelakaan. Penelitian yang sudah dilakukan dalam pengenalan objek bergerak di jalan raya, diantaranya menggunakan Metode K-NN, SVM , CNN dan R-CNN.

Penelitian yang dilakukan Chen menggunakan Metode CNN untuk pengenalan objek kendaraan (Chen *et al.*, 2018). Arsitektur pengenalan objek atau klasifikasi objek menggunakan CNN dapat dilihat pada gambar 2.3. Penelitian Chen dan kawan kawannya ini membangun kerangka kerja yang efisien dan efektif untuk mendeteksi dan klasifikasi kendaraan melalui kamera pengawas lalu lintas. Langkah pertama yang dilakukan oleh Chen dalam penelitian ini adalah mengelompokkan skala kendaran dan rasio aspek kedalam data set kendaraan. Kemudian Chen dan kawan kawan menggunakan Metode CNN untuk mendeteksi objek kendaraan. Pada penelitian ini digunakan teknik fusi fitur untuk menggabungkan fitur tingkat tinggi dan fitur

tingkat rendah serta mendeteksi berbagai ukuran kendaraan pada fitur yang berbeda. Untuk meningkatkan kecepatan, penelitian ini menggunakan arsitektur konvolusi penuh. Metode lainnya yang digunakan untuk menunjang penelitian Chen dalam mendeteksi kendaraan adalah *batch-norm*, *hard example mining*, dan *inception*. Dalam penelitian Chen dibuat kerangka kerja yang efisien dan efektif untuk mendeteksi dan klasifikasi kendaraan melalui kamera pengawas lalu lintas. Penelitian Chen ini memperoleh peningkatan yang signifikan pada penggunaan *Faster R-CNN* yaitu rata-rata presisi (mAP) sebesar 6,5%. Chen juga melakukan testing dengan memori GPU 1.5G dengan kecepatan jaringan 15 FPS menghasilkan pendeteksian kendaraan tiga kali lebih cepat dari *R-CNN*.



Gambar 2. 4 Arsitektur Klasifikasi Objek dengan CNN

Penelitian Xi, menggunakan *Cost-sensitive-Convolutional Neural Network* untuk mendeteksi mobil (Xi *et al.*, 2019). dimana objek mobil memiliki ukuran yang relatif kecil. Dalam kerangka jaringan yang diusulkan, lapisan partisi multi-tugas yang terdiri dari beberapa unit pemilihan sub-tugas pertama kali dikembangkan. Unit pemilihan sub-tugas dibuat dengan memperkenalkan local mask dan penggabungan bukan-nol, yang dapat membagi tugas deteksi kompleks menjadi banyak sub-tugas sederhana. Untuk menangani sub-tugas yang diperoleh, cost-sensitive sub-network diusulkan berdasarkan kerangka kerja R-CNN yang lebih cepat dengan pengenalan kerugian yang biaya yang relatif lebih sedikit. Pada dataset penelitian ini,

metode yang diusulkan memperoleh peta 85,3%, mengungguli metode YOLO2, PVAnet dan SSD.

Kemudian pengenalan objek sepeda motor dilakukan oleh Limantoro. Pada penelitian ini digunakan metode CNN untuk pengenalan objek sepeda motor (Limantoro *et al.*, 2017). Tujuan dari penelitian ini adalah mencari kombinasi arsitektur dan parameter CNN yang terbaik. Eksperimen pertama terdiri atas tiga bobot yang sudah dilatih sedangkan eksperimen kedua mengandung satu bobot yang sudah dilatih. Kinerja bobot terhadap data pengujian pada eksperimen 1 dan eksperimen 2 diukur melalui f1-score masing-masing 0,977, 0,988, 0,989, dan 0,986. Dari hasil percobaan menggunakan sliding window, eksperimen 2 memiliki tingkat error yang lebih rendah untuk memprediksi pengendara sepeda motor dibandingkan dengan eksperimen 1 karena data pelatihan pada eksperimen 1 lebih banyak jumlahnya dan mengandung citra yang lebih variatif.

Beberapa penelitian lain untuk pengenalan kendaraan di jalan raya dilakukan oleh Dewi (DEWI *et al.*, 2019) dan Agustiani (Agustiani, 2019). Pengenalan objek yang lain di jalan raya adalah pengenalan objek pejalan kaki. Pengenalan objek pejalan kaki perlu dilakukan dalam pendeteksian kecelakaan ini karena sering kali kejadian kecelakaan melibatkan pejalan kaki. Dalam penelitian AlDahoul menggunakan pendeteksian manusia dan bukan manusia dari foto udara (AlDahoul *et al.*, 2018). Pengujian dilakukan terhadap 5 aktifitas manusia yaitu menggali, melambai, melempar, berjalan, dan berlari. Penelitian ini membandingkan 3 metode pendeteksian manusia dan bukan manusia menggunakan machine learning yaitu supervised convolution neural network (SCNN), Hierarchical extreme learning machine (H-ELM) dan pretrained CNN model. Hasil Penelitian ini membandingkan antara akurasi dan kecepatan pendeteksian. Penelitian menunjukkan metode Pretrained CNN memiliki akurasi 98,09% mengungguli SCNN dan H-ELM. H-ELM menunjukkan waktu yang lebih efisien dalam melakukan komputasi daripada S-CNN karena tidak membutuhkan pengaturan bobot yang berulang-ulang. Karena dalam H-ELM, bobot ditentukan secara acak.

Pengenalan pejalan kaki, juga dilakukan oleh Gao dan kawan-kawan. Pada penelitian Gao ini digunakan gabungan algoritma deep learning dengan fuzzy logic untuk mendeteksi pejalan kaki (Gao *et al.*, 2020). Kombinasi metode ini menghasilkan kinerja yang lebih baik dibandingkan hanya menggunakan deep learning saja. Dalam proses algoritma deep learning digunakan algoritma *Support Vector Machine* (SVM) dan *Histogram of Oriented Gradients* (HOG) untuk deteksi fitur pejalan kaki. Kinerja deep learning tergantung dari banyaknya data yang dijadikan dataset sebagai data latih, dan sangat menurun kinerjanya jika kualitas gambar yang diproses, memiliki kualitas yang kurang baik karena faktor cuaca dan lingkungan. Penggunaan outline dan gradient sangat baik untuk mengatasi kondisi gambar yang

dipengaruhi cuaca. Karena dengan penggunaan gradient ini tidak terpengaruh oleh kondisi lingkungan.

Setiawan melakukan klasifikasi pengenalan mobil dan pejalan kaki. Pada penelitian ini pendeteksian objek kendaraan dan pejalan kaki diawali dengan input video dari perangkat CCTV yang ditempatkan di pinggir jalan (Setiawan and Yunan, 2020). Video inputan dari CCTV memiliki format 30fps. Setiap frame dari video diproses untuk diidentifikasi. Berikutnya dilakukan pendeteksian ruas jalan yang ada pada video yaitu garis tepi jalan dan garis tengah jalan. Setelah mendeteksi ruas jalan dilakukan proses segmentasi untuk menentukan ROI (region of interest) dari objek yang akan di deteksi, ROI ini digunakan untuk melakukan cropping mobil dan pejalan kaki. Kemudian dilakukan proses ekstraksi fitur dimana tahap ini merupakan tahapan yang sangat penting untuk mengambil dan mengumpulkan fitur dari objek sebelum diinput ke klasifikasi neural network. Proses klasifikasi dilakukan dengan menggunakan metode LVQ (learning vector quantization). hasil ekstraksi fitur yang sudah di kumpulan pada proses sebelumnya akan dibagi menjadi dua bagian, pertama adalah bagian data latih sebanyak 70% dan yang kedua adalah data tes sebanyak 30%.

Pendeteksian pejalan kaki dapat dilakukan dengan metode YOLO (*You look Only Once*) yang merupakan deteksi objek secara real time berdasarkan CNN. Penggunaan YOLO pada pendeteksian pejalan kaki dilakukan oleh Wang (Wang *et al.*, 2020) dan Harahap (Harahap *et al.*, 2019). Dimana penggunaan metode Yolo dapat mengungguli beberapa metode pendeteksian object secara real time lainnya seperti SVM dan K-NN.

2.5 Deteksi Kecepatan dan lintasan


Kecepatan dari objek yang bergerak merupakan salah satu indikator yang dapat digunakan untuk menunjang keputusan adanya kecelakaan di jalan raya secara real time. Kecepatan objek bergerak dalam suatu image didahului dengan melakukan pendeteksian objek pada image (Liu *et al.*, 2018) (Katsuki *et al.*, 2017). Salah satu algoritma yang dapat digunakan untuk mendeteksi kestipasi kecepatan objek bergerak dalam data video adalah *Optical Flow*. *Optical Flow* merupakan suatu gerakan yang dapat terlihat karena adanya pola intensitas kecerahan image. *Optical Flow* mengasumsikan bahwa kecerahan tiap citra adalah konstan dari waktu ke waktu (Qimin *et al.*, 2014). Piksel dari objek yang bergerak diasumsikan bertetangga dan bergerak ke arah yang sama. Metode *Optical Flow* mengasumsikan bahwa intensitas titik yang dipilih tidak berubah dari satu bingkai ke bingkai berikutnya dan titik tersebut dengan tetangganya memiliki gerakan yang searah (Hua *et al.*, 2018) (Gerat *et al.*, 2017). Untuk menghitung kecepatan dari suatu objek dalam image dapat menggunakan persamaan :

$$v_j(k) = \frac{\Delta P(x_j(k), y_j(k))}{\Delta t} \quad (3)$$

$$= \frac{P(x_j(k), y_j(k)) - P(x_j(k-1), y_j(k-1))}{\Delta t} \quad (4)$$

Deteksi kecepatan objek dilakukan untuk mendapatkan perubahan kecepatan sebelum kejadian dan sesudah kejadian. Deteksi kecepatan juga dapat dilakukan dengan Metode *Background Subtraction* (Lugianti *et al.*, 2012) dengan algoritma *Gaussian Mixture Model* (GMM) (Sadewo *et al.*, 2015). Background subtraction (Andrew *et al.*, 2017) akan memisahkan antara latar belakang dengan kendaraan atau objek yang akan diukur kecepatannya. Koordinat titik tengah objek dijadikan sebagai nilai perpindahan objek dalam satuan piksel. Jarak sesungguhnya diukur dalam satuan meter. Jarak pada citra dibatasi dengan *region of interest* (ROI) sebesar 160 piksel. Setelah diperoleh waktu perpindahan tiap pikselnya maka nilai piksel/detik dikonversikan menjadi km/jam..

Objek tracking merupakan proses yang sangat penting dalam computer vision (Iswanto *et al.*, 2019). Proses tracking objek bergerak digunakan untuk mengetahui apakah lintasan pada image yang diobservasi terjadi perpotongan lintasan. Jika terjadi perpotongan lintasan diantara objek yang bergerak akan meningkatkan keputusan sistem bahwa terjadi kecelakaan. Langkah awal dalam mendeteksi lintasan adalah mendeteksi objek yang bergerak terlebih dahulu kemudian dilakukan proses pelacakan objek di setiap frame image yang dianalisa (Gunjal *et al.*, 2018) (Putra *et al.*, 2017) (Delforouzi *et al.*, 2018). Salah satu metode yang dapat digunakan untuk mendeteksi lintasan dari objek yang bergerak adalah kalman filter (KF). KF melakukan estimasi suatu proses dengan mekanisme kontrol umpan-balik dengan cara yang meminimalkan rata-rata dari kesalahan kuadrat (Gunjal *et al.*, 2018). KF Filter mengestimasi state dari proses kemudian mendapat umpan balik berupa nilai hasil pengukuran yang bercampur noise. Algoritma kalman filter terdiri dari 2 bagian yaitu proses prediksi(update waktu) dan koreksi(update pengukuran) (Soleh *et al.*, 2018)(Li *et al.*, 2010)(Li, 2010)(Xu and Chang, 2011)(Taylor *et al.*, 2016) (Marrón *et al.*, 2007). Siklus proses rekursif dari alman filter dapat digambarkan seperti gambar



Gambar 2. 5 Proses Siklus Kalman Filter(Gunjal *et al.*, 2018)

2.6 Pendeteksian Kecelakaan dengan deep learning

Setelah melakukan pengenalan terhadap objek yang bergerak dari input video ke sistem, maka dilakukan proses pengenalan terhadap kejadian kecelakaan. Pengenalan terhadap kejadian kecelakaan diawali dengan pembuatan model kejadian kecelakaan di jalan raya. Beberapa penelitian sudah menggunakan SVM, K-NN, CNN (Ijjina *et al.*, 2019), R-CNN (Shah *et al.*, 2019)(Chang *et al.*, 2019b) untuk proses pengenalan kejadian kecelakaan.

Penelitian yang dilakukan oleh Wang (Wang *et al.*, 2020) dan Tian (Tian *et al.*, 2019) sama-sama menggunakan algoritma Yolo untuk melakukan pendeteksian terhadap kejadian kecelakaan di jalan raya. Pertama, algoritma Retinex digunakan untuk meningkatkan kualitas gambar, dikumpulkan dalam kondisi visibilitas rendah (mis., cuaca hujan lebat, cuaca berkabut, dan malam gelap dengan cahaya redup). Kemudian model Yolo versi 3 dilatih untuk mendeteksi beberapa objek dari gambar, termasuk pejalan kaki / pengendara sepeda yang jatuh, tergulingnya kendaraan, kendaraan yang bergerak / berhenti, pengendara sepeda / pejalan kaki yang bergerak / dihentikan, dan sebagainya. Hasil penelitian Wang(Wang *et al.*, 2020) menunjukkan bahwa kerangka yang diusulkan mencapai tingkat deteksi yang tinggi sebesar 92,5%, dengan tingkat alarm palsu yang relatif rendah yaitu 7,5%. Ada beberapa temuan yang berguna: (1) model yang diusulkan mengungguli model deteksi berbasis aturan empiris; (2) metode peningkatan citra sebagian besar dapat meningkatkan kinerja deteksi kecelakaan dalam kondisi visibilitas rendah; (3) keakuratan deteksi objek (mis., Prediksi kotak pembatas) dapat memengaruhi kinerja deteksi tabrakan, terutama untuk kecelakaan ringan yang melibatkan kendaraan bermotor.

Ravindran melakukan pendeteksian kejadian kecelakaan dengan menggunakan *machine learning*. Metode klasifikasi yang digunakan adalah *Support Vector Machine* kejadian kecelakaan dan memprediksi kecelakaan (Ravindran *et al.*, 2016). Metode SVM dengan kombinasi pembelajaran menggunakan *Histogram of Gradients* (HOG) dan Gray Level co-occurrence matrix (GLCM) diujikan pada dataset yang berbeda yang disebut sebagai DCD1 dan DCD2. Hasil pengujian dengan dataset pertama DCD1 menunjukkan tingkat akurasi sistem 81,83% dan menggunakan dataset kedua mendapatkan tingkat akurasi sistem 64,37%. Kalau melihat tahapan yang dilakukan, penelitian ini lebih cenderung untuk menganalisa gambar dan menyimpulkan peristiwa apa yang terjadi dalam gambar tersebut. Untuk pendeteksian kejadian secara real time kurang tepat digunakan.

Metode yang lain dalam pendeteksian kejadian kecelakakaan dilakukan oleh Huang (Huang *et al.*, 2020). Pendeteksian kecelakaan dalam penelitian Huang menggunakan metode *Convolution Neural Network* (CNN). Untuk prediksi menggunakan beberapa parameter input seperti volume kendaraan yang melintas di jalan raya, kecepatan kendaraan dan jumlah beban yang dibawa oleh kendaraan tersebut. Dari hasil pengujian dengan beberapa metode *machine learning* seperti *K-Nearest Neighbor* (KNN) , SVM dan *Random Forest* (RF) menunjukkan metode CNN memiliki tingkat akurasi pendeteksian kecelakaan paling tinggi dibandingkan KNN,SVM dan RF. Untuk prediksi kecelakaan menggunakan data frame input 1 menit, 5 menit dan 10 menit sebelum kejadian kecelakaan. Prediksi kecelakaan dalam penelitian ini menunjukkan data 10 menit sebelum kejadian kurang bagus untuk dipakai sebagai input data kecelakaan.

Chang (Chang *et al.*, 2019) juga menggunakan metode CNN dalam mendeteksi kejadian kecelakaan. Penelitian ini bertujuan untuk membuat suatu sistem yang akan terpasang di mobil dengan menganalisa keadaan sekeliling mobil jika terjadi suatu kecelakaan. Kondisi sekitar diambil melalui sensor dan kamera yang nantinya mengolah data tersebut untuk mengambil suatu keputusan. Sistem ini lebih ditujukan ketika kecelakaan lalu lintas terjadi di daerah berpenduduk jarang atau pengemudi adalah satu-satunya orang di dalam kendaraan. Jika pengemudi mengalami hilang kesadaran, tidak ada yang akan mengirim pesan kondisi bahaya kepada pihak berwenang. Sistem melakukan pendeteksian kecelakaan menggunakan metode *Inception CNN* untuk mendeteksi tabrakan satu kendaraan dan head-on berkecepatan tinggi, menganalisis situasi, dan membunyikan alarm. Dalam artikel ini diusulkan penggunaan sistem Internet of Vehicle (IoV) berbasis deep learning yang disebut DeepCrash, yang mencakup platform telematika in-vehicle infotainment (IVI) dengan sensor deteksi tabrakan kendaraan dan kamera depan, pembelajaran berbasis cloud server, dan platform manajemen berbasis cloud. Ketika tabrakan terjadi, informasi deteksi kecelakaan diunggah ke server database berbasis


cloud untuk pengenalan kecelakaan kendaraan yang bertabrakan dan pemberitahuan kondisi darurat. Hasil percobaan menunjukkan bahwa akurasi deteksi tabrakan lalu lintas dapat mencapai 96% dan waktu respons rata-rata untuk pengumuman terkait keadaan darurat sekitar 7 detik.

2.7 Metode Reinforcement Learning

Reinforcement-learning (RL) adalah metode machine learning yang sangat berkaitan dengan bagaimana agent perangkat lunak harus mengambil action di dalam suatu environment. RL adalah kelas umum algoritma yang merupakan bagian dari metode deep learning yang membantu Anda memaksimalkan sebagian dari reward kumulatif. RL yang bertujuan memungkinkan agen untuk belajar bagaimana berperilaku di lingkungan dan RL tidak boleh dilihat sebagai karakteristik kelas tertentu dari metode pembelajaran, melainkan sebagai masalah pembelajaran atau paradigma (van Otterlo and Wiering, 2012).

Inti RL dalam pembelajaran mesin adalah tentang bagaimana pengambilan keputusan berurutan. Ini akan di dasarkan pada tugas memutuskan dari pengalaman, urutan tindakan untuk tampil di lingkungan yang tidak pasti untuk mencapai beberapa tujuan. Tugas pengambilan keputusan yang berurutan mencakup berbagai kemungkinan aplikasi dengan potensi memengaruhi banyak domain, seperti robotika, perawatan kesehatan, jaringan pintar, keuangan, mobil tanpa pengemudi, dan banyak lagi. RL mengusulkan kerangka kerja formal untuk masalah ini. Ide utamanya adalah bahwa agen artifisial dapat belajar dengan berinteraksi dengan lingkungannya (Collins, 2018), mirip dengan agen biologis. Menggunakan pengalaman dikumpulkan, agen buatan harus dapat mengoptimalkan beberapa tujuan diberikan dalam bentuk imbalan kumulatif (Fang *et al.*, 2020) (Bernstein and Burnaev, 2018) (Gherega *et al.*, 2012). Pendekatan ini pada prinsipnya berlaku untuk semua jenis masalah pengambilan keputusan berurutan yang mengandalkan pengalaman masa lalu. Lingkungan mungkin stokastik, agen mungkin saja mengamati sebagian informasi tentang keadaan saat ini, pengamatan mungkin berdimensi tinggi (misalnya, bingkai dan deret waktu), agen mungkin dengan bebas mengumpulkan pengalaman di lingkungan atau sebaliknya.

Ada beberapa factor yang mendasari dalam penggunaan RL adalah untuk membantu menemukan situasi mana yang membutuhkan tindakan, membantu menemukan action mana yang menghasilkan reward tertinggi (Gherega *et al.*, 2012) (Sun and Gong, 2019) (Hafiz and Bhat, 2020) selama periode yang lebih lama. RL juga menyediakan fungsi *reward* bagi *agent* pembelajaran. .



Gambar 2. 6 Model Deep RL (Lu *et al.*, 2019)

2.8 Pengujian

Pengujian unjuk kerja algoritma sistem dalam *mechine learning* dapat menggunakan acuan *Confusion Matrix*, nilai akurasi dan presisi. *Confusion Matrix* merupakan sebuah tabel yang terdiri dari 4 kombinasi berbeda dari nilai prediksi dan nilai kenyataannya(aktual). Empat kondisi yang kemungkinan terjadi dalam pengujian Algoritma *Mechine Learning* adalah kondisi *true positif* (TP), *true negatif* (TN), *false positif* (FP), dan *false negatif* (FN) (Bethanney Janney *et al.*, 2020) (Kotu and Deshpande, 2019) (Nisbet *et al.*, 2018). Kondisi *true positif* merupakan data positif yang terdeteksi benar. Kondisi *true negatif* adalah jumlah data negatif yang terdeteksi dengan benar. Kondisi *false positif* merupakan data negatif namun terdeteksi sebagai data positif. Sedangkan *false negatif* adalah data positif, tetapi terdeteksi sebagai data negatif. Dari nilai TP, TN, FP dan FN dapat dihitung nilai akurasi, presisi dan recall (Kim *et al.*, 2020). Nilai akurasi menunjukkan seberapa akurat sistem dapat mendeteksi data dengan benar. Nilai akurasi merupakan perbandingan antara data yang dideteksi benar dengan keseluruhan data. Nilai presisi menunjukkan jumlah data kategori positif yang dideteksi secara benar dibagi dengan total data positif. Nilai recall merupakan persentase data positif yang terdeteksi dengan benar oleh algoritma sistem. *Confusion Matrix* dapat diperoleh tingkat akurasi dan presisi dengan rumus :

$$akurasi = \frac{TP+TN}{TP+TN+FP+FN} * 100\% \quad (5)$$

$$presisi = \frac{TP}{FP+TP} * 100\% \quad (6)$$

$$recall = \frac{TP}{FN+TP} * 100\% \quad (7)$$

dari sini kita memperoleh mean average precision (mAP) yang dihitung dengan rumus :

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (8)$$

dimana : N adalah jumlah data AP,

AP adalah *Average Precision*

mAP ataupun AP banyak digunakan untuk mengevaluasi unjuk kerja dari sistem yang menggunakan algoritma CNN (Kumar and Srivastava, 2020)(Kulik and Shtanko, 2020) (Mao *et al.*, 2019) (Ramcharan *et al.*, 2019)(Henderson and Ferrari, 2017)(Chauhan *et al.*, 2019).

BAB III. KERANGKA BERPIKIR DAN KONSEP PENELITIAN

3.1 Kerangka Berpikir

Penelitian yang sudah pernah dilakukan pada deteksi kejadian kecelakaan lalu lintas dan algoritma pendukung pendeteksian tersebut lebih banyak menggunakan metode *supervised learning* dimana dilakukan proses training sistem terlebih dahulu untuk mendapatkan model. Setelah model terbentuk baru kemudian diujikan ke kondisi real. Dalam membuat model ada supervisornya, dimana sistem dibimbing dengan memberikan label di tiap data yang akan dipakai sebagai data training. Sebagai contoh untuk gambar mobil, maka di masing-masing gambar mobil kita isikan tag mobil. Data berikutnya misalkan gambar sepeda motor, maka di setiap gambar sepeda motor kita labeli dengan tag sepeda motor. *Supervised learning* lebih sering digunakan untuk memprediksi pola, dimana pola yang akan dibuat sudah ada contoh yang lengkap. *Supervised learning* biasanya digunakan untuk proses klasifikasi objek dari suatu gambar.

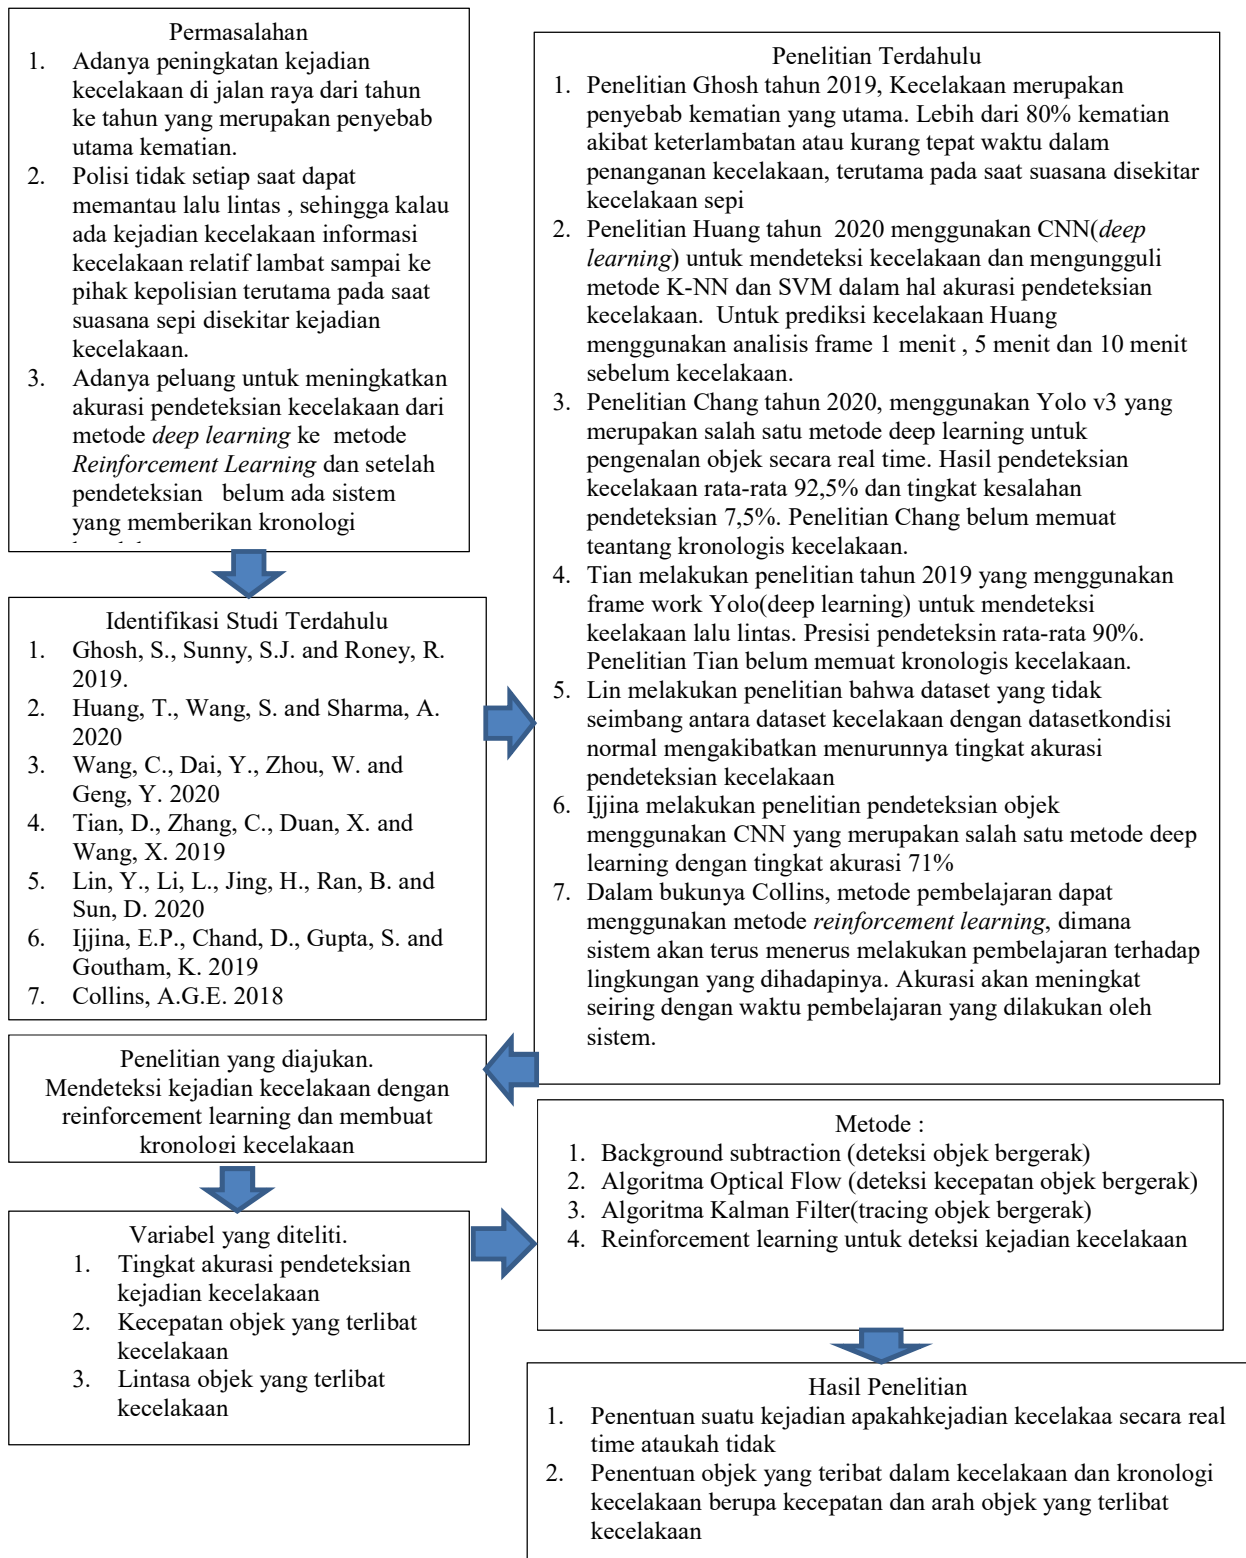
Disisi lain ada metode *RL* (Collins, 2018) yang merupakan salah satu cabang dari *mechine learning*. *RL* lebih menitikberatkan kepada cara dari agent untuk mengambil keputusan terhadap umpan balik dari lingkungannya. Agen mencari nilai maksimal dari *reward* yang diberikan dari keputusan yang diambil untuk jangka panjang. Pada setiap keputusan yang diambil akan melakukan proses belajar dari pengalaman sebelumnya. *RL* dalam proses pembelajarannya menggunakan *trial and error* dan setiap interaksi dengan lingkungan menghasilkan informasi, yang digunakan agen untuk memperbarui pengetahuannya. Dilihat dari proses pengolahan data *RL* lebih cenderung digunakan dalam pengambilan keputusan sedangkan *supervised learning* lebih cenderung digunakan untuk analisis data seperti klasifikasi objek.

Dalam penelitian ini dilakukan pendeteksian kecelakaan dengan *RL* karena lebih cenderung untuk memutuskan, apakah suatu frame video tersebut memuat kejadian kecelakaan ataukah tidak. Untuk membuat kronologi kecelakaan kita memerlukan klasifikasi objek yang terlibat dalam kecelakaan sehingga dalam proses klasifikasi objeknya menggunakan *supervised learning* dengan membangun model terlebih dahulu. Kecepatan dan lintasan yang dilalui objek juga menjadi parameter untuk menentukan kejadian kecelakaan. Kecepatan dan lintasan objek ini untuk menghindari adanya kesalahan pendeteksian. Misalnya pada kejadian mobil hancur yang ditarik oleh mobil derek. Kondisi ini bukan merupakan kejadian kecelakaan, sehingga

perlu mengetahui perubahan kecepatan objek dan apakah terjadi persilangan lintasan antara objek yang terlibat kecelakaan

3.2 Konsep Penelitian

Pendeteksian kejadian kecelakaan dan pembuatan kronologi kecelakaan ini, melibatkan beberapa algoritma diantaranya *Background Subtraction*, metode *Supervised Learning* dengan RCNN, *Kalman filter*, *optical flow* dan *reinforcement learning*. Algoritma *background subtraction* digunakan untuk mendeteksi objek yang bergerak karena kemungkinan besar yang terlibat kecelakaan adalah objek yang bergerak. Supervised learning dengan CNN digunakan untuk melakukan klasifikasi dari objek yang bergerak tersebut. Klasifikasi objek diperlukan untuk membangun kronologi objek apa saja yang terlibat kecelakaan. Kalman filter digunakan untuk mendeteksi kecepatan masing-masing objek yang bergerak, jika terjadi penurunan kecepatan secara drastis kemungkinan objek tersebut terlibat kecelakaan. Algoritma *optical flow* dan *template matching* digunakan untuk mengetahui lintasan yang dilalui oleh objek yang bergerak. Perpotongan lintasan antara objek yang bergerak merupakan salah satu parameter untuk pengambilan keputusan bahwa terjadi kecelakaan. Metode *reinforcement learning* digunakan untuk pendeteksian kejadian kecelakaan. Konsep penelitian pendeteksian kejadian kecelakaan dengan RL ini dapat dilihat pada gambar 3.1



Gambar 3. 1 Konsep Penelitian


BAB IV. METODE PENELITIAN

4.1 Rancangan Penelitian


Adapun rancangan penelitian yang akan diajukan dalam pendeteksian kejadian kecelakaan ini melalui beberapa tahapan proses. Proses – proses yang digunakan dalam penelitian ini adalah (1) Proses deteksi objek bergerak dan proses klasifikasi objek, (2) Proses deteksi kecepatan objek bergerak, (3) Proses deteksi lintasan objek bergerak, (4) Proses pendeteksian kejadian kecelakaan. Arsitektur sistem dapat dilihat pada gambar 4.1.

Penelitian ini dilakukan beberapa tahapan yaitu tahapan pertama pendeteksian objek bergerak dan mengklasifikasikan objek bergerak tersebut. Pada tahap pertama ini dilakukan dengan input data berupa video keadaan di jalan raya. Dari video keadaan jalan raya ini dilakukan pendeteksian objek yang bergerak per frame video. Pendeteksian objek yang bergerak di jalan raya dilakukan dengan menggunakan algoritma *background subtraction*. Setelah diperoleh objek yang bergerak di jalan raya dilakukan proses klasifikasi objek dengan algoritma CNN sehingga objek yang bergerak tersebut dapat dikenali dan diklasifikasikan sebagai objek mobil, sepeda motor, pejalan kaki dan hewan.


Tahap kedua dari penelitian ini , dimulai dengan input dari objek jalan raya yang sudah terdeteksi dan dikenali. Objek yang melintas di jalan raya ini akan diestimasi kecepatannya. Proses pendeteksian kecepatan objek ini menggunakan Algoritma *Optical Flow*. Input data berupa *streaming video* terlebih dahulu diberi pembatas garis awal dan garis akhir pendeteksian kecepatan. Jika objek yang bergerak tersebut sudah sampai pada garis akhir pendeteksian dan dikenali sebagai objek yang sama seperti objek pada garis awal pendeteksian, maka dilakukan penghitungan estimasi kecepatan. Adapun diagram alir pendeteksian kecepatan dapat dilihat pada gambar 4.4.




Gambar 4. 1 Arsitektur Pendeteksian Kejadian Kecelakaan dengan Reinforcement Learning



Gambar 4. 2 Diagram Alir Pendeteksian Objek Bergerak dengan Background Subtraction




Gambar 4. 3 Diagram Alir Klasifikasi Objek Menggunakan CNN



Gambar 4. 4 Diagram Alir Estimasi Kecepatan Objek Bergerak dengan Optical Flow


Tahap ketiga dilakukan proses pendeteksian lintasan(*trajektory*) dari objek yang bergerak. Pendeteksian lintasan ini menggunakan Metode *Kalman Filter*. Objek bergerak yang sudah terklasifikasi di jalan raya ini masing masing dilakukan pendeteksian lintasan yang dilalui. Input video yang sudah terbagi menjadi urutan frame citra, selanjutnya diproses untuk menentukan

region of interest (ROI). ROI akan dipakai untuk pemilihan area objek yang digunakan sebagai acuan proses pelacakan objek. ROI digunakan untuk memilih objek yang dibutuhkan saja, sehingga piksel di luar ROI tidak akan dipilih. Objek yang sudah terpilih sebagai target akan ditandai dengan *bounding box*. Setelah itu dilakukn proses penghitungan *centroid*. Hasil penghitungan centroid ini akan menjadi data masukan pada proses kalman filter untuk mendapatkan prediksi objek di frame berikutnya. Proses deteksi lintasan objek yang bergerak dapat dilihat pada gambar 4.5.

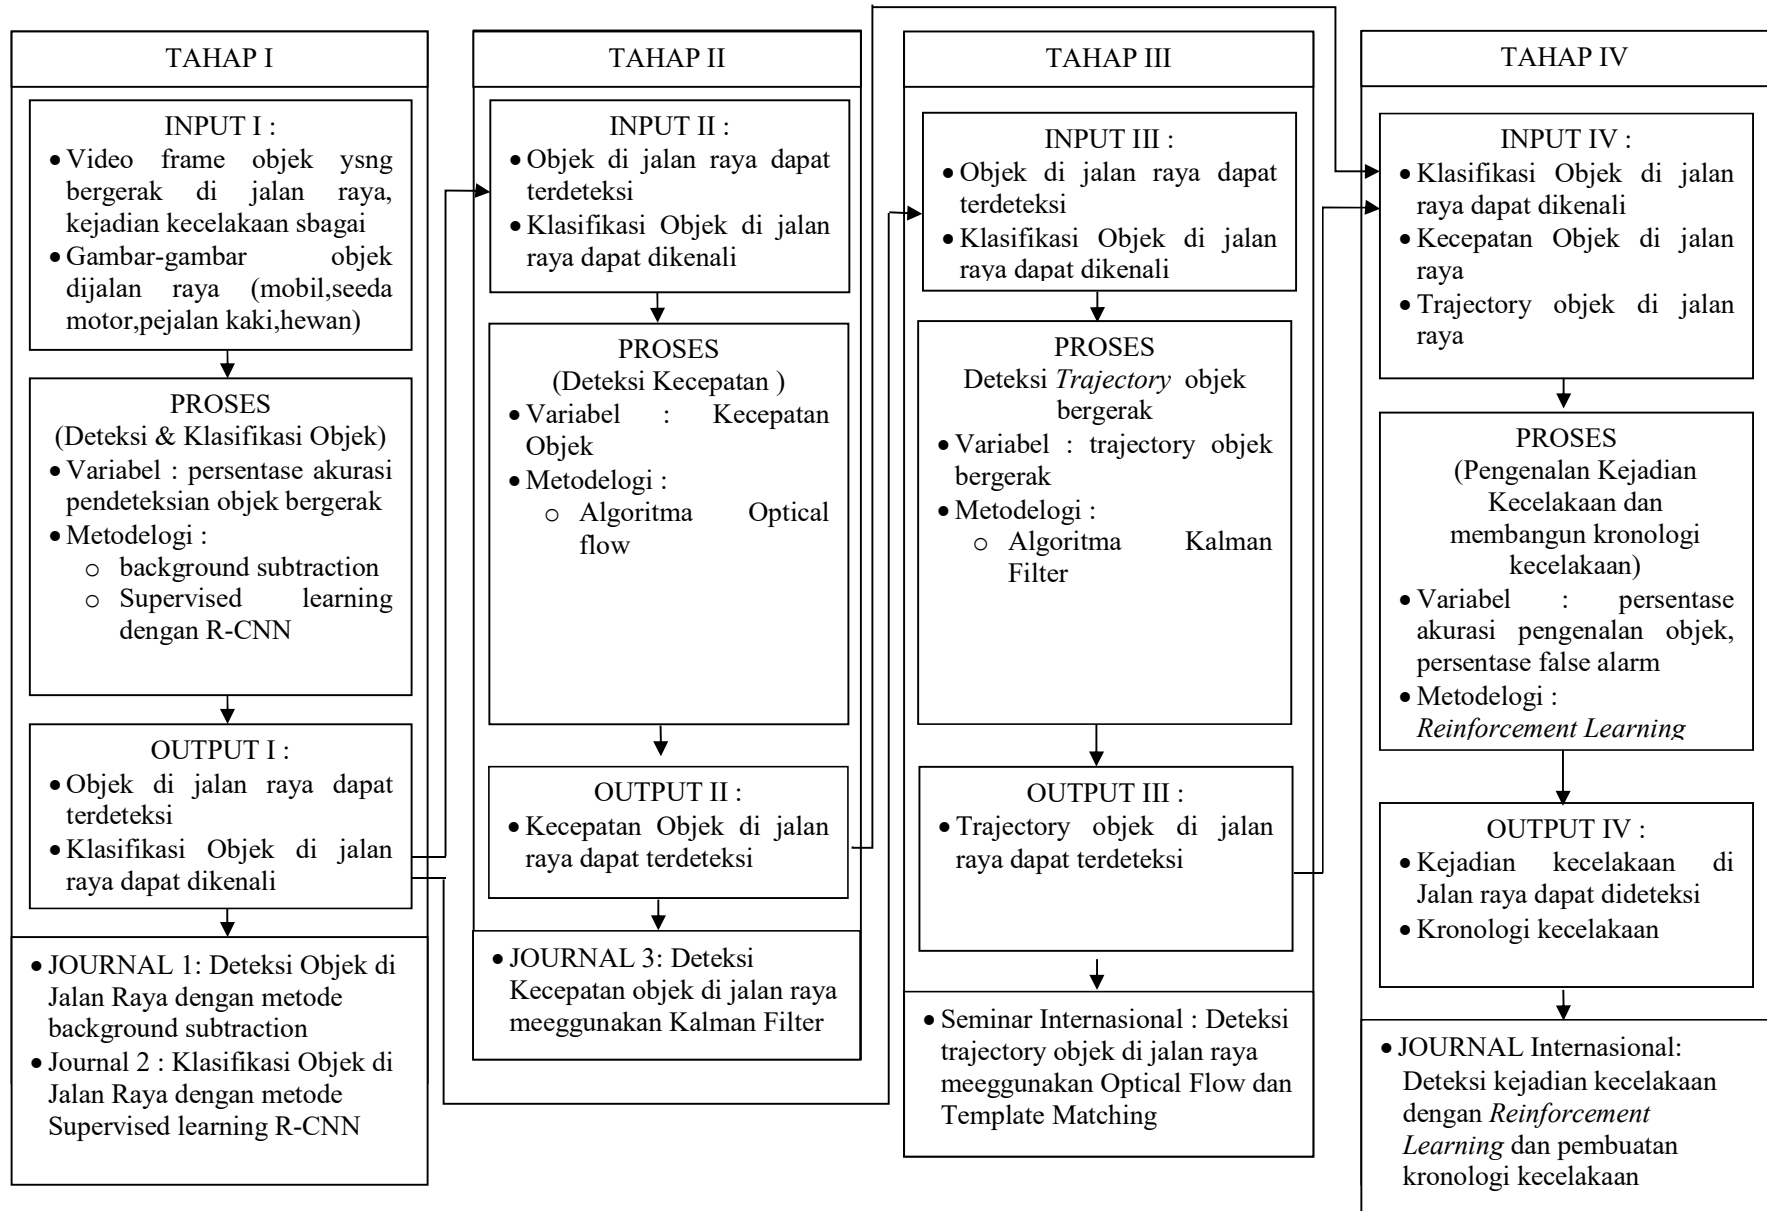


Gambar 4. 5 Diagram Alir Deteksi Lintasan dengan Kalman Filter

Tahap keempat dimulai dengan proses input dari data objek bergerak di jalan raya yang sudah terklasifikasi. Kemudian dilakukan proses pengenalan kejadian kecelakaan menggunakan metode *reinforcement learning*. Diagram alir klasifikasi pengenalan kejadian kecelakaan dapat dilihat pada gambar 4.6 Pada tahap keempat ini juga dilakukan pembuatan kronologi kejadian kecelakaan. Jadi pada tahap ini kejadian kecelakaan sudah terdeteksi terlebih dahulu. Kronologi kecelakaan meliputi objek yang terlibat kecelakaan, kecepatan objek, arah objek yang dapat dianalisa melalui lintasan yang dilalui (*trajectory*). Penggambaran tahapan penelitian dapat dilihat pada gambar 4.7 tentang mapping penelitian.



Gambar 4. 6 Diagram alir klasifikasi kejadian kecelakaan dengan *Reinforcement Learning*



Gambar 4. 7 Mapping Penelitian

4.2 Lokasi dan Waktu Penelitian

Penelitian yang dilakukan untuk membangun sistem pendeteksian kejadian kecelakaan dengan *RL* ini dilakukan dengan membuat kode kode program yang dilakukan secara mandiri di laboratorium.

Penelitian ini dilakukan sebagai prasyarat dalam menyelesaikan Program Studi Doktor, sehingga waktu yang dibutuhkan untuk melakukan penelitian disesuaikan dengan masa studi perkuliahan yaitu selama tiga tahun, terhitung mulai dari semester I sampai dengan semester V

4.3 Ruang Lingkup Penelitian

Pada penelitian sistem pendeteksian kejadian kecelakaan dengan *RL* ini, dibatasi sebagai berikut :

- a. Video yang diolah adalah video hasil rekaman CCTV di jalan raya.
- b. Video yang diolah adalah pada saat siang hari dan cuaca yang cerah.
- c. Pembuatan program menggunakan bahasa pemrograman Python dengan pustaka OpenCV.
- d. Informasi yang dapat diterima oleh polisi berupa kronologis awal kejadian kecelakaan seperti klasifikasi objek yang terlibat kecelakaan, kecepatan objek yang terlibat dan arah atau lintasan yang dilalui beberapa saat sebelum terjadinya kecelakaan

4.4 Penentuan Sumber Data

Adapun sumber data dari penelitian sistem pendeteksian kejadian kecelakaan dengan *RL* ini adalah :

- a. Video kecelakaan dari Youtube.com
- b. Gambar kecelakaan dari Polda Bali dan Dinas Perhubungan Kodya Denpasar dan Kabupaten Badung
- c. Dataset yang bebas digunakan untuk penelitian machine learning di internet contoh dari <https://github.com/OlafenwaMoses/Traffic-Net>

4.5 Variabel Penelitian

Variabel yang digunakan dalam penelitian pendeteksian kecelakaan dengan RL ini adalah :

- a. Kecepatan Sebelum Kejadian
- b. Kecepatan sesudah kejadian
- c. Tingkat Prediksi jalur objek yang intersection
- d. Penurunan Kecepatan (kendaraan lainnya setelah kejadian)
- e. Tingkat akurasi pengenalan kejadian kecelakaan

4.6 Bahan Penelitian

Bahan utama dalam penelitian pendeteksian kecelakaan dengan RL ini adalah gambar dataset dari kendaraan (mobil, sepeda motor), pejalan kaki dan hewan dan dataset gambar kecelakaan. Untuk testing berupa video streaming dari CCTV yang terpasang di jalan raya.

4.7 Instrumen Penelitian

Adapun instrumen yang digunakan dalam melakukan penelitian ini berupa perangkat keras dan perangkat lunak. Perangkat keras yang digunakan untuk melakukan penelitian adalah :

- Processor Intel Core i7 8250 8GB SSD 512GB Win10, GPU NVIDIA Geforce GT 1050Ti 4GB.

Sedangkan perangkat Lunak yang digunakan adalah :

- Python dengan pustaka OpenCV dan framework YOLO
- Window 10

4.8 Prosedur Penelitian

Prosedure penelitian pendeteksian kejadian kecelakaan di jalan raya ini menggunakan beberapa tahapan yaitu :

1. Tahap Analisis

Pada tahap ini, dilakukan penentuan kebutuhan terhadap model sistem yang akan dikembangkan, meliputi data yang terlibat dalam sistem baik masukan maupun keluaran, pengguna sistem, serta proses-proses yang dibutuhkan untuk mengolah data..

2. Tahap Desain

Pada tahap ini, dilakukan proses perancangan model sistem, meliputi pendefinisian dan pembuatan basis data, perancangan algoritma, dan perancangan antarmuka sebagai media interaksi antara pengguna dan sistem.

3. Tahap Pengkodean

Pada tahap ini, dilakukan proses pengkodean rancangan algoritma menggunakan instrumen perangkat keras dan perangkat lunak, sehingga menghasilkan sistem yang siap untuk diuji.

4. Tahap Pengujian

Pada tahap ini, dilakukan pengujian terhadap sistem, untuk menentukan apakah sistem perlu diperbaiki, atau siap untuk diimplementasikan.

DAFTAR PUSTAKA

- A. Dawwd, S. and M. AL Layla, N. 2015. Training Acceleration of Multi-Layer Perceptron using Multicore CPU and GPU under MATLAB Environment. *AL-Rafdain Engineering Journal (AREJ)*, 23 (3), pp.136–148.
- Agustiani, D. 2019. Implementasi Machine Learning dan Computer Vision pada Pengembangan Sistem Otomasi Klasifikasi dan Perhitungan Kendaraan. In: *Seminar Nasional Dinamika Informatika*. pp.16–19.
- Akula, A., Khanna, N., Ghosh, R., Kumar, S., Das, A. and Sardana, H.K. 2014. Adaptive contour-based statistical background subtraction method for moving target detection in infrared video sequences. *Infrared Physics and Technology*, 63, pp.103–109. Elsevier B.V.
- AlDahoul, N., Md Sabri, A.Q. and Mansoor, A.M. 2018. Real-Time Human Detection for Aerial Captured Video Sequences via Deep Models. *Computational intelligence and neuroscience*, 2018, p.1639561.
- Alsmadi, M.K., Omar, K. Bin, Noah, S.A. and Almarashdah, I. 2009. Performance comparison of multi-layer perceptron (Back Propagation, Delta Rule and Perceptron) algorithms in neural networks. *2009 IEEE International Advance Computing Conference, IACC 2009*, 7 (March), pp.296–299.
- Andrew, A., Buliali, J.L. and Wijaya, A.Y. 2017. Deteksi Kecepatan Kendaraan Berjalan di Jalan Menggunakan OpenCV. *Jurnal Teknik ITS*, 6 (2), pp.366–371.
- Astawa, I.N.G.A., Darma Putra, I.K.G., Sudarma, M. and Hartati, R.S. 2020. KomNET: Face Image Dataset from Various Media for Face Recognition. *Data in Brief*, 31, p.105677. Elsevier Inc.
- Bernstein, A. V. and Burnaev, E. V. 2018. Reinforcement learning in computer vision. (April), p.58.
- Bethanney Janney, J., Roslin, S.E. and Kumar, S.K. 2020. Analysis of skin lesions using machine learning techniques. In: *Computational Intelligence and Its Applications in Healthcare*. Elsevier. pp.73–90.
- Bortnikov, M., Khan, A., Khattak, A.M. and Ahmad, M. 2020. Accident Recognition via 3D CNNs for Automated Traffic Monitoring in Smart Cities. In: *Advances in Intelligent Systems and Computing*.

- Chang, W.-J., Chen, L.-B. and Su, K.-Y. 2019a. DeepCrash: A Deep Learning-Based Internet of Vehicles System for Head-On and Single-Vehicle Accident Detection With Emergency Notification. *IEEE Access*, 7, pp.148163–148175. Institute of Electrical and Electronics Engineers Inc.
- Chang, W.J., Chen, L.B. and Su, K.Y. 2019b. DeepCrash: A deep learning-based internet of vehicles system for head-on and single-vehicle accident detection with emergency notification. *IEEE Access*, 7, pp.148163–148175.
- Chauhan, M.S., Singh, A., Khemka, M., Prateek, A. and Sen, R. 2019. Embedded CNN based vehicle classification and counting in non-laned road traffic. *arXiv*.
- Chen, L., Ye, F., Ruan, Y., Fan, H. and Chen, Q. 2018. An algorithm for highway vehicle detection based on convolutional neural network. *Eurasip Journal on Image and Video Processing*, 2018 (1), pp.1–7. EURASIP Journal on Image and Video Processing.
- Chen, S., Wang, W. and van Zuylen, H. 2009. Construct support vector machine ensemble to detect traffic incident. *Expert Systems with Applications*, 36 (8), pp.10976–10986. Elsevier Ltd.
- Collins, A.G.E. 2018. Learning Structures Through Reinforcement. In: R. Morris, A. Bornstein and A.B.T.-G.-D.D.M. Shenhav, eds. *Goal-Directed Decision Making*. Elsevier, pp.105–123.
- Darma Putra, I.K.G., Jayantha Putra, I.P.D., Fauzi, R. and Witarsyah, D. 2020a. Classification of Tomato Plants Diseases Using Convolutional Neural Network. *International Journal on Advanced Science, Engineering and Information Technology*, 10 (5), pp.1821–1827.
- Darma Putra, I.K.G., Sri Asra, D.M., Dwiva Hardijaya, I.G.N., Surya Prabawa, I.G.G. and Satia Widiatmika, I.M.A. 2020b. Medical vision: web and mobile medical image retrieval system based on google cloud vision. *International Journal of Electrical and Computer Engineering (IJECE)*, 10 (6), p.5974.
- Delforouzi, A., Pamarthi, B. and Grzegorzec, M. 2018. Training-Based Methods for Comparison of Object Detection Methods for Visual Object Tracking. *Sensors*, 18 (11), p.3994.
- Detikcom. 2020. *Kecelakaan Lalu Lintas Naik 24%, Kerugian Capai Rp 2,7 M*.
- DEWI, I.A., KRISTIANA, L., DARLIS, A.R. and DWIPUTRA, R.F. 2019. Deep Learning RetinaNet based Car Detection for Smart Transportation Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 7 (3), p.570.
- Fadlia, N. and Kosasih, R. 2019. Klasifikasi Jenis Kendaraan Menggunakan Metode Convolutional Neural Network (Cnn). *Jurnal Ilmiah Teknologi dan Rekayasa*, 24 (3), pp.207–215.

- Fang, W., Pang, L. and Yi, W. 2020. Survey on the Application of Deep Reinforcement Learning in Image Processing. *Journal on Artificial Intelligence*, 2 (1), pp.39–58.
- Gajić, L., Cvetnić, D., Bezdan, T. and Baćanin Džakula, N. 2020. Multi-Layer Perceptron Training by Genetic Algorithms. pp.301–306.
- Gao, F., Wang, C. and Li, C. 2020. A Combined Object Detection Method With Application to Pedestrian Detection. *IEEE Access*, 8, pp.194457–194465.
- Gerat, J., Sopiak, D., Oravec, M. and Pavlovicova, J. 2017. Vehicle speed detection from camera stream using image processing methods. *Proceedings Elmar - International Symposium Electronics in Marine*, 2017-Septe (September), pp.201–204.
- Gherega, A., Udrea, R.M. and Rădulescu, M. 2012. A Q-learning approach to decision problems in image processing. *MMEDIA - International Conferences on Advances in Multimedia*, (c), pp.60–66.
- Ghosh, S., Sunny, S.J. and Roney, R. 2019. Accident Detection Using Convolutional Neural Networks. *2019 International Conference on Data Science and Communication, IconDSC 2019*, pp.1–6. IEEE.
- Gunjal, P.R., Gunjal, B.R., Shinde, H.A., Vanam, S.M. and Aher, S.S. 2018. Moving Object Tracking Using Kalman Filter. In: *2018 International Conference On Advances in Communication and Computing Technology (ICACCT)*. IEEE.pp.544–547.
- Gupta, S. and Choudhary, V. 2019. Accident Detection in Live Surveillance. *IJCSN- International Journal of Computer Science and Network*, 8 (3).
- Hafiz, A.M. and Bhat, G.M. 2020. Image Classification by Reinforcement Learning with Two-State Q-Learning. *arXiv*.
- Harahap, M., Elfrida, J., Agusman, P., Rafael, M., Abram, R. and Andrianto, K. 2019. Sistem Cerdas Pemantauan Arus Lalu Lintas Dengan YOLO (You Only Look Once v3). *Seminar Nasional APTIKOM*, pp.367–376.
- Henderson, P. and Ferrari, V. 2017. End-to-end training of object class detectors for mean average precision. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10115 LNCS, pp.198–213.
- Hendrayana, P.B.S., Rahardian, R.L. and Sudarma, M. 2017. Application of Neural Network Overview In Data Mining. *International Journal of Engineering and Emerging Technology*, 2 (1), p.94.
- Herman, G., Milshteyn, A., Lin, A., Garcia, M., Liu, C., Guillaume, D., Rad, K. and Boussalis, H. 2014. Implementation of Kalman Filter on PSoC-5 Microcontroller for Mobile Robot Localization. *Journal of Communication and Computer*, 11, pp.469–477.

- Hua, S., Kapoor, M. and Anastasiu, D.C. 2018. Vehicle Tracking and Speed Estimation from Traffic Videos. In: *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. IEEE.pp.153–1537.
- Huang, T., Wang, S. and Sharma, A. 2020. Highway crash detection and risk estimation using deep learning. *Accident Analysis and Prevention*, 135 (April 2019), p.105392. Elsevier.
- Ijjina, E.P., Chand, D., Gupta, S. and Goutham, K. 2019. Computer Vision-based Accident Detection in Traffic Surveillance. In: *2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*. IEEE.pp.1–6.
- Iswanto, I.A., Choa, T.W. and Li, B. 2019. Object tracking based on meanshift and particle-Kalman filter algorithm with multi features. *Procedia Computer Science*, 157, pp.521–529. Elsevier B.V.
- Katsuki, T., Morimura, T. and Inoue, M. 2017. Traffic Velocity Estimation from Vehicle Count Sequences. *IEEE Transactions on Intelligent Transportation Systems*, 18 (7), pp.1700–1712.
- Kepolisian, N.R.I. 2013. *PERATURAN KEPALA KEPOLISIAN NEGARA REPUBLIK INDONESIA NOMOR 15 TAHUN 2013 TENTANG TATA CARA PENANGANAN KECELAKAAN LALU LINTAS*.
- Khaghani, F. 2020. A Deep Learning Approach to Predict Accident Occurrence Based on Traffic Dynamics A Deep Learning Approach to Predict Accident Occurrence Based on Traffic Dynamics.
- Kim, B., Yuvaraj, N., Sri Preethaa, K.R., Santhosh, R. and Sabari, A. 2020. Enhanced pedestrian detection using optimized deep convolution neural network for smart building surveillance. *Soft Computing*, 1. Springer Berlin Heidelberg.
- Kotu, V. and Deshpande, B. 2019. Model Evaluation. In: *Data Science*. Elsevier.pp.263–279.
- Kulik, S. and Shtanko, A. 2020. Using convolutional neural networks for recognition of objects varied in appearance in computer vision for intellectual robots. *Procedia Computer Science*, 169 (2019), pp.164–167. Elsevier B.V.
- Kumar, A. and Srivastava, S. 2020. Object Detection System Based on Convolution Neural Networks Using Single Shot Multi-Box Detector. *Procedia Computer Science*, 171 (2019), pp.2610–2617. Elsevier B.V.
- Kumar, S. and Yadav, J. Sen. 2016. Video object extraction and its tracking using background subtraction in complex environments. *Perspectives in Science*, 8, pp.317–322. Elsevier GmbH.
- Lazaro, A., Buliali, J.L. and Amaliah, B. 2017. Deteksi Jenis Kendaraan di Jalan Menggunakan OpenCV. *Jurnal Teknik ITS*, 6 (2).

- Lee, I.J. 2011. An accident detection system on highway using vehicle tracking trace. *2011 International Conference on ICT Convergence, ICTC 2011*, pp.716–721.
- Li, X. 2010. Object tracking using an adaptive Kalman filter combined with mean shift. *Optical Engineering*, 49 (2), p.020503.
- Li, X., Wang, K., Wang, W. and Li, Y. 2010. A multiple object tracking method using Kalman filter. *2010 IEEE International Conference on Information and Automation, ICIA 2010*, 1 (1), pp.1862–1866.
- Li, Z., Liu, P., Wang, W. and Xu, C. 2012. Using support vector machine models for crash injury severity analysis. *Accident Analysis and Prevention*, 45, pp.478–486. Elsevier Ltd.
- Limantoro, S.E., Kristian, Y. and Purwanto, D.D. 2017. Deteksi Pengendara Sepeda Motor Menggunakan Deep Convolutional Neural Networks. In: *Seminar Nasional Teknologi Informasi dan Komunikasi*. pp.79–86.
- Limantoro, S.E., Kristian, Y. and Purwanto, D.D. 2018. Pemanfaatan Deep Learning pada Video Dash Cam untuk Deteksi Pengendara Sepeda Motor. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, 7 (2), pp.3–9.
- Liu, K., Ye, Y., Li, X. and Li, Y. 2018. A Real-Time Method to Estimate Speed of Object Based on Object Detection and Optical Flow Calculation. *Journal of Physics: Conference Series*, 1004 (1).
- Lu, J., Ren, L. and Rao, Y. 2019. *Deep Reinforcement Learning for Computer Vision Tutorial*.
- Lugianti, I., Yushman Sari, J. and Purwanti Ningrum, I. 2012. Deteksi Kecepatan Kendaraan Bergerak Berbasis Video Menggunakan Metode Frame Difference. In: *SEMINAR NASIONAL TEKNOLOGI TERAPAN BERBASIS KEARIFAN LOKAL (SNT2BKL)*. pp.324–332.
- Mangalraj, P.L.V., L. and HARSHINI. 2019. Realization of Location Based Services For Crowded Public Areas. In: *2019 1st International Conference on Innovations in Information and Communication Technology (ICIICT)*. IEEE. pp.1–7.
- Mao, H., Yang, X. and Dally, W.J. 2019. A delay metric for video object detection: What average precision fails to tell. *arXiv*.
- Marrón, M., García, J.C., Sotelo, M.A., Cabello, M., Pizarro, D., Huerta, F. and Cerro, J. 2007. Comparing a Kalman filter and a particle filter in a multiple objects tracking application. *2007 IEEE International Symposium on Intelligent Signal Processing, WISP*.
- Nguyen The, C. and Shashev, D. 2018. Methods and Algorithms for Detecting Objects in Video Files. *MATEC Web of Conferences*, 155, p.01016.
- Nisbet, R., Miner, G. and Yale, K. 2018. Model Evaluation and Enhancement. In: *Handbook of Statistical Analysis and Data Mining Applications*. Elsevier. pp.215–233.

- van Otterlo, M. and Wiering, M. 2012. Reinforcement Learning and Markov Decision Processes. In: *Reinforcement Learning: State-of-the-Art*. pp.3–42.
- Ozbayoglu, M., Kucukayan, G. and Dogdu, E. 2016. A real-time autonomous highway accident detection model based on big data processing and computational intelligence. *Proceedings - 2016 IEEE International Conference on Big Data, Big Data 2016*, pp.1807–1813.
- Parsa, A.B., Taghipour, H., Derrible, S. and Mohammadian, A. (Kouros). 2019. Real-time accident detection: Coping with imbalanced data. *Accident Analysis and Prevention*, 129 (January), pp.202–210. Elsevier.
- Pavithra R., J.M. 2018. Automatic Object Detection and Collision. *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 6 (II), pp.2255–2258.
- Poda, X. and Qirici, O. 2018. Shape detection and classification using OpenCV and Arduino Uno. *CEUR Workshop Proceedings*, 2280, pp.128–136.
- Putra, D.E.W., Rasmana, S.T. and Puspasari, I. 2017. DETEKSI DAN TRACKING OBYEK BERBENTUK BOLA MENGGUNAKAN KALMAN FILTER Dwi. *JCONES Journal of Control and Network Systems*, 6 (1), pp.213–221.
- Putri, N.N. 2016. Aplikasi Pendeteksi Objek bergerak pada Image Sequence Dengan Metode Background Subtraction. *Jurnal Teknologi Rekayasa Volume*, 21 (3), pp.162–172.
- Qimin, X., Xu, L., Mingming, W., Bin, L. and Xianghui, S. 2014. A methodology of vehicle speed estimation based on optical flow. In: *Proceedings of 2014 IEEE International Conference on Service Operations and Logistics, and Informatics*. IEEE.pp.33–37.
- Ramcharan, A., McCloskey, P., Baranowski, K., Mbilinyi, N., Mrisho, L., Ndalaha, M., Legg, J. and Hughes, D.P. 2019. A mobile-based deep learning model for cassava disease diagnosis. *Frontiers in Plant Science*, 10.
- Ravindran, V., Viswanathan, L. and Rangaswamy, S. 2016. A Novel Approach to Automatic Road-Accident Detection using Machine Vision Techniques. *International Journal of Advanced Computer Science and Applications*, 7 (11), pp.235–242.
- Reinius, S. 2013. Object recognition using the OpenCV Haar cascade-classifier on the iOS platform. *Institutionen för Informationsteknologi, Uppsala Universitet*.
- Rokhana, R., Priambodo, J., Karlita, T., Sunarya, I.M.G., Yuniarno, E.M., Purnama, I.K.E. and Purnomo, M.H. 2019. Convolutional Neural Network untuk Pendeteksian Patah Tulang Femur pada Citra Ultrasonik B-Mode. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, 8 (1), p.59.
- Sadewo, S.S., Sumiharto, R. and Candradewi, I. 2015. Sistem Pengukur Kecepatan Kendaraan

- Berbasis Pengolahan Video. *IJEIS (Indonesian Journal of Electronics and Instrumentation Systems)*, 5 (2), p.177.
- Seiffert, U. 2001. Multi-Layer Perceptron Training by Genetic Algorithms. In: *Proceedings of the European Symposium on Artificial Neural Networks - ESANN'2001*. Beograd, Serbia.pp.159–164.
- Setiawan, H. and Yunan, A. 2020. KLASIFIKASI MOBIL BERJALAN DAN PEJALAN KAKI UNTUK PENGGUNAAN AUTOMATIC INCIDENT DETECTION SEBAGAI UPAYA PENGURANGAN RESIKO KECELAKAAN DI JALAN RAYA. *Jurnal Inotera*, 5 (1), pp.50–55.
- Shah, A.P., Lamare, J.B., Nguyen-Anh, T. and Hauptmann, A. 2019. CADP: A Novel Dataset for CCTV Traffic Camera based Accident Analysis. *Proceedings of AVSS 2018 - 2018 15th IEEE International Conference on Advanced Video and Signal-Based Surveillance*, (i), pp.1–9. IEEE.
- Sieniutycz, S. 2020. Complex systems of neural networks. In: *Complexity and Complex Thermo-Economic Systems*. Elsevier.pp.51–84.
- Soleh, M., Jati, G. and Hilman, M.H. 2018. MULTI OBJECT DETECTION AND TRACKING USING OPTICAL FLOW DENSITY – HUNGARIAN KALMAN FILTER (OFD - HKF) ALGORITHM FOR VEHICLE COUNTING. *Jurnal Ilmu Komputer dan Informasi*, 11 (1), p.17.
- Statistik, B.P. 2020. *Jumlah Kecelakaan, Koban Mati, Luka Berat, Luka Ringan, dan Kerugian Materi yang Diderita Tahun 1992-2018*.
- Sudana, O., Gunaya, I.W. and Putra, I.K.G.D. 2020. Handwriting identification using deep convolutional neural network method. *Telkomnika (Telecommunication Computing Electronics and Control)*, 18 (4), pp.1934–1941.
- Sugano, H. and Miyamoto, R. 2010. Highly optimized implementation of OpenCV for the Cell Broadband Engine. *Computer Vision and Image Understanding*, 114 (11), pp.1273–1281. Elsevier Inc.
- Sun, L. and Gong, Y. 2019. Active Learning for Image Classification: A Deep Reinforcement Learning Approach. *Proceedings - 2nd China Symposium on Cognitive Computing and Hybrid Intelligence, CCHI 2019*, pp.71–76. IEEE.
- Suparmanta, S. 2019. Analisis Kecelakaan Lalu Lintas Yang Terjadi Pada Anak-Anak studi kasus : Daerah Istimewa Yogyakarta. *Jurnal Penelitian Transportasi Darat*, 20 (2), p.107.
- Surendar, E., Thomas, V.M. and Posonia, A.M. 2016. Animal tracking using background subtraction on multi threshold segmentation. In: *2016 International Conference on*

- Circuit, Power and Computing Technologies (ICCPCT)*. IEEE.pp.1–6.
- Sushmitha, S., Satheesh, N. and Kanchana, V. 2020. Multiple Car Detection, Recognition and Tracking in Traffic. In: *2020 International Conference for Emerging Technology (INCET)*. IEEE.pp.1–5.
- Taylor, L.E., Mirdanies, M. and Saputra, R.P. 2016. Optimized object tracking technique using Kalman filter. *Journal of Mechatronics, Electrical Power, and Vehicular Technology*, 7 (1), p.57.
- Tian, D., Zhang, C., Duan, X. and Wang, X. 2019. An Automatic Car Accident Detection Method Based on Cooperative Vehicle Infrastructure Systems. *IEEE Access*, 7, pp.127453–127463. IEEE.
- Vieira, S., Lopez Pinaya, W.H. and Mechelli, A. 2020. Introduction to machine learning. In: A. Mechelli and S.B.T.-M.L. Vieira, eds. *Machine Learning*. Elsevier.pp.1–20.
- Wang, C., Dai, Y., Zhou, W. and Geng, Y. 2020. A Vision-Based Video Crash Detection Framework for Mixed Traffic Flow Environment Considering Low-Visibility Condition. *Journal of Advanced Transportation*, 2020.
- Xi, X., Yu, Z., Zhan, Z., Yin, Y. and Tian, C. 2019. Multi-Task Cost-Sensitive-Convolutional Neural Network for Car Detection. *IEEE Access*, 7, pp.98061–98068.
- Xu, S. and Chang, A. 2011. Robust Object Tracking Using Kalman Filters with Dynamic Covariance. *Cornell University*.
- Yazdi, M. and Bouwmans, T. 2018. New trends on moving object detection in video images captured by a moving camera: A survey. *Computer Science Review*, 28, pp.157–177.
- Yuan, F. and Cheu, R.L. 2003. Incident detection using support vector machines. *Transportation Research Part C: Emerging Technologies*, 11 (3–4), pp.309–328.
- Zelinsky, A. 2009. Learning OpenCV---Computer Vision with the OpenCV Library (Bradski, G.R. et al.; 2008)[On the Shelf]. *IEEE Robotics & Automation Magazine*, 16 (3), pp.100–100.