

---

## **Estimasi Panjang Antrian Pada Simpang Bersinyal Dengan Menggunakan *Artificial Neural Network***

**Sara Respati\*<sup>1</sup>, Mohamad Isram<sup>1</sup>, Fatmawati<sup>1</sup>, Sri Kusri<sup>2</sup>**

<sup>1</sup>Department of Civil Engineering, Politeknik Negeri Balikpapan, Indonesia

<sup>2</sup>Dinas Perhubungan Balikpapan, Balikpapan, Indonesia

Email korespondensi: sara.wibawaning@poltekba.ac.id

### **ABSTRACT**

Signalized intersections are nodes in the transportation network where vehicles in different directions meet and are critical points for congestion. Vehicle queue length is one of the performance parameters of a signalized intersection. Long queues of vehicles are at high risk of accidents involving many vehicles. Feedback signal control (actuated signal control) can be used to improve intersection performance. One of the variables that can be used as a feedback input is the length of the vehicle queue. Traffic in Indonesia is mixed traffic where various types of vehicles use the same road lanes and with low lane discipline. This causes the traffic system to become complex and to be stochastic and non-linear. Queue length modeling using a static linear algorithm is unable to capture the phenomenon of this complex traffic system. Therefore, this study aims to build a queue length model based on machine learning, that is, using an artificial neural network (ANN). This model studies traffic systems with historical data so that through the training process it can model queue lengths with a good degree of accuracy. An estimation model was built and applied to a section of the Muara Rapak signalized intersections, Balikpapan. Data on queue length for 10 days, 2 hours/day, obtained using CCTV and direct field surveys. The results of the model test show that ANN has a good level of accuracy with MAE, RMSE and MAPE of 3.8 m, 4.9 m and 6%, respectively.

**Keywords:** Artificial Neural Network; Queue Length; Signalized Intersection

### PENDAHULUAN

Simpang bersinyal merupakan titik kritis dalam jaringan transportasi dimana merupakan salah satu sumber kemacetan. Salah satu faktor kunci yang mempengaruhi kinerja simpang bersinyal adalah panjang antrian kendaraan. Panjang antrian kendaraan merupakan ruang longitudinal yang ditempati oleh kendaraan yang berhenti pada simpang bersinyal. Pada arus lalu-lintas tinggi, seperti pada jam sibuk, pengguna jalan mengalami kondisi berkendara yang tidak

nyaman. Untuk meningkatkan tingkat kenyamanan pengendara dan meningkatkan kinerja simpang, dapat digunakan simpang dengan desain kendali sinyal umpan balik atau *actuated signal control*. Kontrol ini menggunakan data kondisi simpang terbaru sebagai umpan balik untuk mengatur waktu siklus simpang bersinyal tersebut. Dengan pengaturan yang sesuai dengan kondisi simpang, antrian kendaraan pada simpang dapat dikurangi. Selain itu, hal ini secara optimal memanfaatkan infrastruktur yang telah ada, seperti CCTV yang diinstal di simpang bersinyal. Salah satu komponen yang dapat digunakan untuk sistem umpan balik adalah panjang antrian kendaraan. Faktor panjang antrian telah banyak digunakan untuk sistem kontrol umpan balik berbasis antrian yang dikembangkan. Maka, estimasi Panjang antrian merupakan komponen fundamental dalam sistem kontrol adaptif lalu-lintas (Comert dan Cetin, 2011). Berbagai penelitian telah dilakukan mengenai hal ini, namun sebagian besar model estimasi menerapkan kondisi lalu-lintas yang homogen dengan kondisi pengguna kendaraan yang disiplin.

Karakteristik arus lalu-lintas pada lalu-lintas campuran berbasis non-lajur (tanpa disiplin lajur) berbeda secara signifikan dengan lalu-lintas homogen dengan disiplin jalur (Asaithambi, Kanagaraj et al., 2016). Kebiasaan mengemudi, pergerakan kendaraan menyamping dan membujur memiliki dampak yang signifikan terhadap pembentukan panjang antrian pada lalu-lintas campuran. Maka, model estimasi panjang antrian yang digunakan untuk kondisi lalu-lintas dengan disiplin lajur tidak cocok untuk digunakan pada kondisi lalu-lintas campuran tanpa disiplin lajur. Jithender dan Mehar (2022) membangun model regresi multivariat untuk panjang antrian dalam kondisi lalu-lintas campuran dengan variabel volume pendekat, jumlah minimum kendaraan dalam antrian, lebar pendekat, waktu merah, dan proporsi mobil dan kendaraan roda dua. Berdasarkan analisis korelasi, variabel-variabel tersebut ditetapkan pengaruhnya terhadap model regresi. Sehingga, model regresi harus dikalibrasi untuk setiap lokasi. Studi ini juga menunjukkan bahwa panjang antrian lapangan tidak dapat diestimasi dengan baik oleh model antrian M/M/1 dan estimasi berbasis antrian HCM (Transportation Research Board, 2010). Dua model antrian ini merupakan model yang dikembangkan untuk lalu-lintas homogen dengan disiplin lajur. Harahap, Darmawan, Fajar, Ceha, and Rachmiatie (2019) menggunakan pemodelan dan simulasi untuk memperkirakan lamanya waktu tunggu kendaraan pada simpang. Model yang dikembangkan didasarkan pada teori pola kedatangan dan keberangkatan acak M/M/1. Faktor komposisi kendaraan tidak diperhitungkan dalam studi yang disebutkan. Anusha, Vanajakshi, and Subramanian (2022) menggunakan pendekatan Kalman-Filter untuk mengestimasi antrian dan tundaan kondisi lalu-lintas campuran. Dalam penelitian tersebut, antrian didefinisikan sebagai jumlah kendaraan dalam antrian. Dalam penelitian ini, luaran dari model estimasi adalah panjang antrian dalam satuan panjang.

Pada kondisi lalu-lintas homogen dengan disiplin lajur, panjang antrian kendaraan dikontrol oleh panjang kendaraan. Dalam lalu-lintas campuran tanpa disiplin lajur, panjang kendaraan tidak dapat menjadi acuan panjang antrian kendaraan. Di sisi lain, komposisi kendaraan merupakan salah satu faktor utama dalam menentukan panjang antrian. Dibandingkan dengan kendaraan roda dua (MC), mobil penumpang memiliki *gap* longitudinal dan lateral yang lebih lebar antar kendaraan. Karena *gap* lateral dan longitudinal yang lebih kecil pada sepeda motor, kepadatan jalan menjadi lebih tinggi ketika proporsi sepeda motor tinggi. Karena banyaknya kombinasi jenis kendaraan yang berada di depan (*leader*) dan yang dibelakangnya (*follower*) pada lalu-lintas campuran, maka ruang longitudinal yang berada di antara kendaraan bervariasi nilainya (Gowri & Sivanandan, 2015) (Gowri dan Sivanandan, 2015). Lebar mobil penumpang yang lebih kecil dari lebar lajur jalan menyebabkan sepeda motor mengisi ruang kosong tersebut. Sepeda motor mampu melakukan manuver zigzag dengan lambat dan bergerak mendekati bagian depan simpang (Gowri & Sivanandan, 2015).

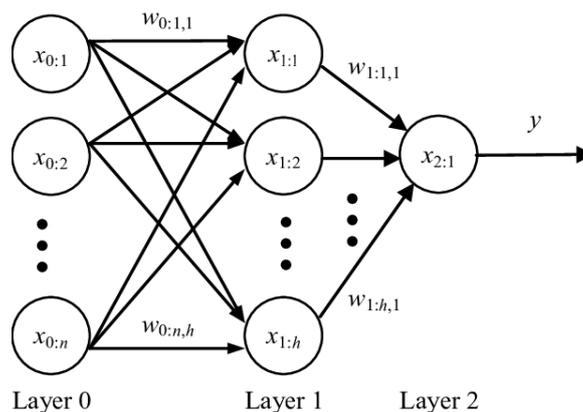
Berdasarkan penjelasan di atas, pada kondisi lalu-lintas campuran tanpa disiplin lajur, panjang antrian bersifat kompleks dan nonlinear. Hal ini menyebabkan panjang antrian tidak dapat diestimasi dengan baik menggunakan model parametrik. Pada model parametrik, estimasi dilakukan berdasarkan distribusi data dan menggunakan asumsi awal mengenai hubungan awal antara input dan output. Sehingga, model parametrik memiliki kekurangan untuk diterapkan pada suatu sistem yang kompleks dan nonlinear yang tidak memiliki variasi yang seragam pada variable-variabelnya. Di sisi lain, model non parametrik tidak memerlukan asumsi mengenai distribusi data dan memiliki fleksibilitas yang tinggi untuk memodelkan suatu sistem yang kompleks. *Machine learning* merupakan model non parametrik dengan konsep *data driven*, yaitu model dibangun berdasarkan data historis, sehingga fleksibel dan tidak diperlukan asumsi awal terhadap distribusi data tersebut.

Model *machine learning* telah diaplikasikan untuk mengestimasi panjang antrian. Artificial neural networks (ANN) dan Support Vector Machine (SVM) telah diaplikasikan untuk mengestimasi panjang antrian di terminal ferry (Zhang, Zou, Tang, Ash, & Wang, 2016). Selain itu, Random Forest (RF) telah digunakan untuk mengestimasi panjang antrian dengan menggunakan data dari GPS dan *licence plate recognition* (LPR) (Liu, An, Yasir, Lu, & Xia, 2022). Berdasarkan penjelasan di atas, maka penelitian ini bertujuan untuk mengetahui karakteristik antrian kendaraan pada kondisi lalu-lintas campuran dan untuk mengestimasi panjang antrian kendaraan dengan menggunakan model *machine learning* berupa ANN. Algoritma *machine learning* ini diaplikasikan pada simpang bersinyal Muara Rapak, Balikpapan.

## METODE PENELITIAN

*Machine learning* merupakan sebuah metode *data driven*, yaitu membangun model berdasarkan data. Semakin banyak data yang dipelajari, maka model atau algoritma mampu mengenali sistem dengan baik dan memiliki akurasi yang tinggi. Aplikasi ilmu kecerdasan buatan ini pun bisa digunakan pada berbagai macam industri dan terus digunakan oleh peneliti, salah satunya adalah dalam perhitungan panjang antrian pada simpang bersinyal.

ANN atau jaringan saraf tiruan merupakan algoritma yang proses bekerjanya menyerupai jaringan saraf otak manusia dan salah satu model *machine learning* yang sering digunakan untuk pemodelan sistem yang kompleks. ANN menghasilkan model yang bersifat non-linear dengan memiliki banyak layer (kecuali pada kasus *single perceptron*). Konsep dasar ANN dapat dilihat pada Gambar 1. ANN terdiri dari layer input, *hidden layer(s)*, dan layer output. Input layer dapat terdiri dari satu atau lebih neuron. Hidden layer adalah lapisan antara input layer dan output layer. Koneksi pada neuron layer ini diberi bobot (*weight*) yang diperbaharui pada proses *learning* sampai dengan *stop criteria* terpenuhi. Layer output merupakan lapisan terakhir dari sistem. Secara umum, konsep kerja sebagai berikut: input layer menerima input ke masing-masing node nya, setelah masing-masing node di input layer memperoleh data yang dibutuhkan maka akan dikalikan dengan *weight*-nya (bobot) menghasilkan sum (jumlah) atau yang lebih dikenal dengan akumulator, lalu akumulator tersebut akan dimasukkan kedalam Fungsi Aktivasi yang digunakan dengan persamaan  $Y = F(NET)$ . Contohnya, pada Gambar 1, nilai  $x_{1:1}$ , diperoleh dari penjumlahan Layer 0 dikalikan dengan masing-masing *weight*-nya, dimana formulasinya dapat dilihat pada Persamaan 1.



**Gambar 1.** Konsep Dasar ANN

$$x_{1:1} = \sum_{i=1}^I x_{0:i} w_{0:i} \quad (1)$$

Hubungan antar node diasosiasikan dengan suatu nilai yang disebut dengan bobot atau *weight*. Setiap node memiliki output, error dan *weight*-nya masing-masing. Output merupakan keluaran dari suatu node. Error merupakan tingkat kesalahan yang terdapat dalam suatu node dari proses yang dilakukan. *Weight* merupakan bobot dari node tersebut ke node yang lain pada layer yang berbeda. Bobot awal dapat dililih secara random dan di inialisasi dengan nilai yang relatif kecil, yaitu berkisar antara -0,1 sampai 0,1. Pada tahap pelatihan, bobot tersebut akan mengalami penyesuaian melalui suatu proses perhitungan matematik agar tercapai nilai bobot yang sesuai. Proses *training* suatu neural network terdiri dari proses *forward*, *backward*, dan *update weight*. Dalam proses training digunakan *learning function* yang diantaranya adalah *gradient descent* dan *Lavenberg-Marquardt learning function*. Semakin banyak data yang digunakan, maka semakin baik proses *training* dari model ANN dan semakin kecil pula tingkat error yang dihasilkan di output layer-nya, dengan demikian semakin kecil juga error suatu sistem.

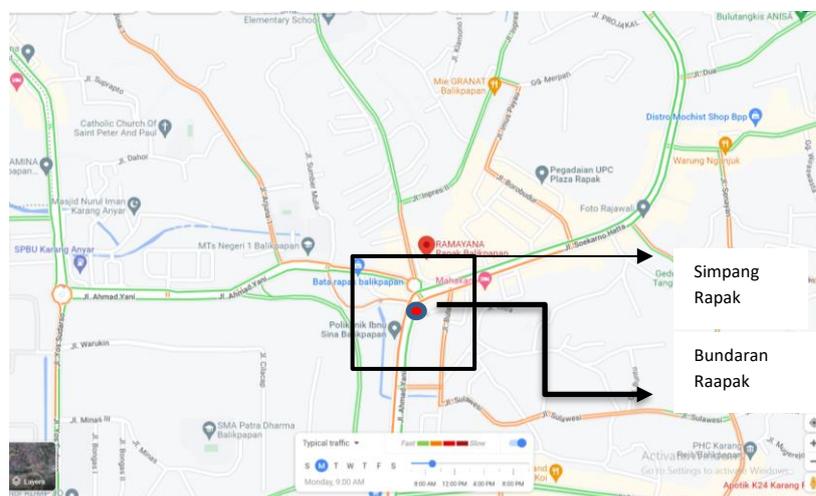
Gao et al. (2020) mengembangkan model dengan menggunakan Deep ANN untuk mengestimasi panjang antrian di simpang bersinyal dengan menggunakan data CCTV. Model Deep ANN mampu membaca jumlah kendaraan di simpang dan menjadikannya input pada proses selanjutnya. Sebelumnya, Gao, Han, Dong, Xiong, and Du (2019) telah membangun model prediksi panjang antrian dengan menggunakan ANN dan menunjukkan bahwa ANN dapat memprediksi panjang antrian dengan akurasi yang tinggi. Chen, Lin, Yeh, Cho, and Wu (2022) menggunakan Deep ANN untuk memprediksi kendaraan yang melewati simpang pada saat lampu hijau pada kondisi mixed traffic.

Selain panjang antrian, ANN juga telah digunakan untuk memodelkan parameter lainnya. Contohnya, pada kondisi *mixed traffic*, Jammula, Bera, and Ravishankar (2018) mengembangkan model untuk memprediksi waktu tempuh dengan menggunakan ANN. Hasilnya menunjukkan ANN memiliki akurasi yang lebih baik dibandingkan model regresi sederhana. ANN dibangun dengan beberapa skenario input, sehingga dapat diketahui parameter apa yang mempengaruhi hasil dan input apa saja yang dapat memberikan estimasi dengan akurasi yang tinggi. Kajian mengenai panjang antrian pada kondisi lalu-lintas campuran dengan menggunakan ANN masih minim aplikasinya. Maka dari itu, penelitian ini bertujuan untuk membangun model ANN untuk mengestimasi panjang antrian kendaraan di simpang bersinyal dengan kondisi lalu-lintas campuran tanpa disiplin lajur.

## Lokasi Dan Data Penelitian

Penelitian ini menggunakan data antrian kendaraan pada simpang bersinyal di kota Balikpapan, Kalimantan Timur. Titik kemacetan di Balikpapan banyak terjadi persimpangan jalan protokol, salah satunya pada simpang lima Muara Rapak. Pada jam sibuk, terjadi antrian kendaraan yang cukup panjang pada beberapa lengan persimpangan tersebut, termasuk pada lengan jalan dari arah turunan Rapak. Lengan simpang ini menjadi perhatian baik pemerintah kota maupun warga Balikpapan, karena kecelakaan fatal telah beberapa kali terjadi di lengan ini. Geometri jalan pada lengan simpang ini memiliki kelandaian yang cukup tinggi sehingga seringkali menyebabkan kendaraan berat mengalami resiko jika dalam kondisi tidak prima sehingga dapat menyapu kendaraan-kendaraan didepannya yang sedang mengantri di simpang tersebut.

Rekayasa lalu-lintas dapat dijadikan solusi untuk mengurangi panjang antrian di lengan simpang kritis, seperti pada kasus simpang Muara Rapak. Dengan data CCTV yang telah terinstal pada 51 titik di kota Balikpapan, data antrian kendaraan dapat diperoleh dan dapat digunakan untuk membangun model yang dapat mengestimasi panjang antrian kendaraan. Lokasi penelitian ditunjukkan pada Gambar 2. Pengambilan data dilakukan selama 10 hari pada pada hari kerja dan jam sibuk.

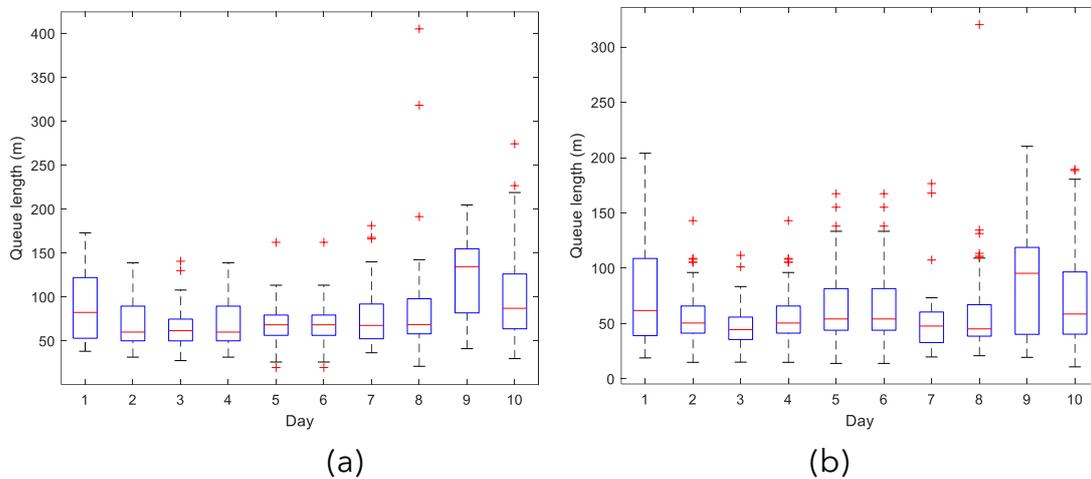


**Gambar 2.** Peta lokasi Penelitian

## Karakteristik Antrian Kendaraan

Gambar 3 menunjukkan boxplot atau sebaran dari data panjang antrian kendaraan untuk 10 hari, yang terdiri dari 47 cycles perharinya. Dapat dilihat bahwa rata-rata dari panjang antrian (garis merah pada tengah boxplot) untuk seluruh hari bervariasi dari sekitar 50 m sampai dengan 130 m. Selain itu dapat dilihat pula sebaran data untuk data panjang antrian per hari juga memiliki variasi yang tinggi yang ditunjukkan dengan lebarnya batas atas dan bawah dari boxplot;

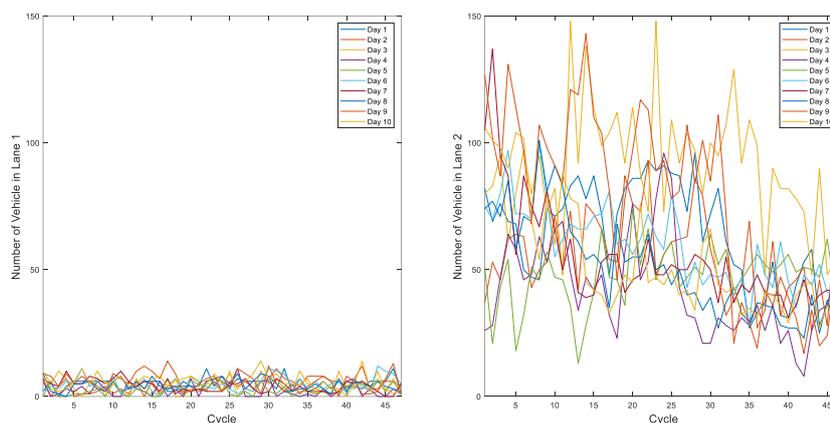
terdapat pula outliers dari data antrian yang ditunjukkan oleh tanda plus berwarna merah. Dari Gambar 3, dapat dilihat antrian Lajur 1 lebih tinggi dari Lajur 2.



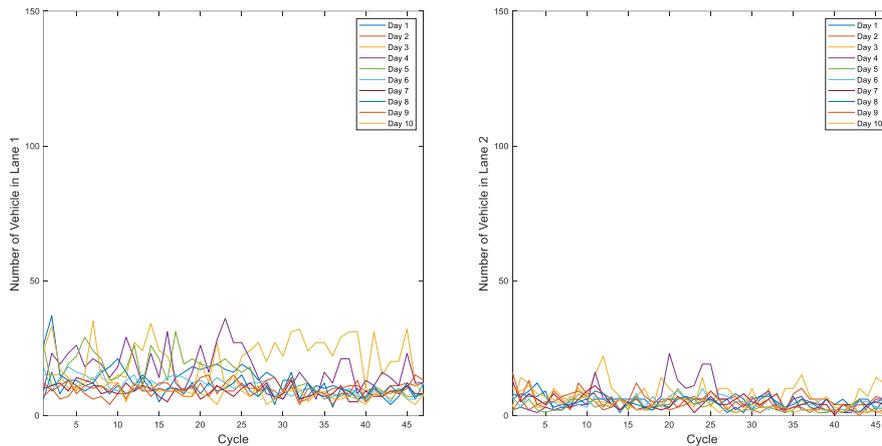
**Gambar 3.** Boxplot data panjang antrian (a) Lajur 1 dan (b) Lajur 2 setiap siklus untuk 10 hari survey

### Karakteristik Komposisi Kendaraan Pada Antrian

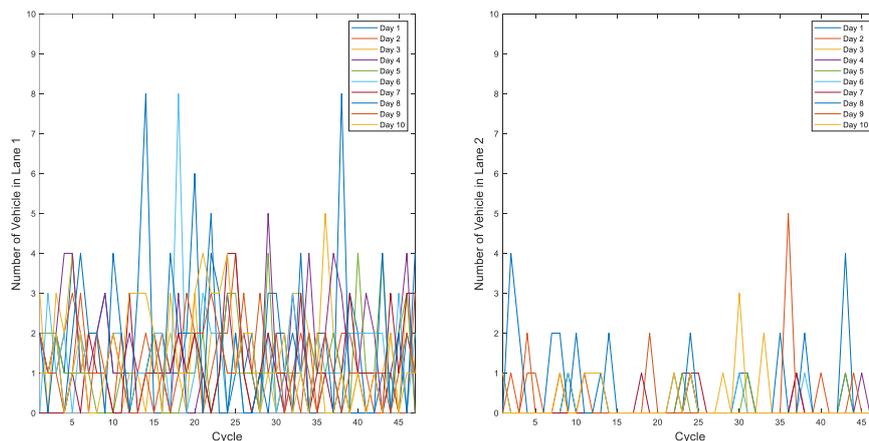
Komposisi kendaraan berdasarkan lajur (lane 1 dan lane 2) per jenis kendaraan dapat dilihat pada grafik di bawah ini. **Gambar 4** menunjukkan bahwa jumlah MC pada antrian di Lajur 2 lebih tinggi dibandingkan dengan MC di Lajur 1. Sedangkan pada kasus LV, lebih banyak LV berhenti di Lajur 1 dibandingkan dengan Lajur 2 (**Gambar 5**), hal yang sama terjadi pada kasus HV (**Gambar 6**).



**Gambar 4.** Komposisi kendaraan motor (MC) pada lane 1 dan lane 2 untuk 47 siklus APIL dan 10 hari survey



**Gambar 5.** Komposisi kendaraan light vehicle (LV) pada lane 1 dan lane 2 untuk 47 siklus APIL dan 10 hari survey



**Gambar 6.** Komposisi kendaraan light vehicle (LV) pada lane 1 dan lane 2 untuk 47 siklus APIL dan 10 hari survey

### Estimasi Panjang Antrian Kendaraan Menggunakan Ann

Estimasi panjang antrian kendaraan pada lalu-lintas campuran di lokasi studi menggunakan ANN, menggunakan tiga input yang terdiri dari jumlah MC, LV and HV yang mengantri. Output dari estimasi berupa panjang antrian. Studi ini menggunakan 70% data untuk proses *training* dan 30% untuk *testing*.

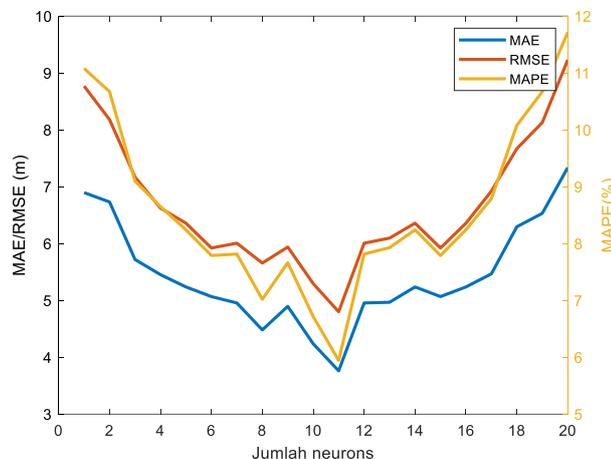
Dalam proses estimasi diperlukan pemilihan algoritma *training* yang digunakan untuk memperbaharui *weight* setiap nodes sehingga error yang dihasilkan lebih kecil. Dalam penelitian ini, digunakan tiga algoritma *training* yang terdiri dari *Levenberg-Marquardt backpropagation*, *Bayesian regularization* dan *Scaled conjugate gradient backpropagation*. Algoritma yang memberikan error terkecil akan dipilih untuk selanjutnya menentukan arsitektur ANN berupa jumlah *neuron* pada *hidden layers*.

Tingkat akurasi dari estimasi dilihat dari nilai *mean absolute error* (MAE), *root mean squared error* (RMSE) dan *mean absolute percentage error* (MAPE). Digunakan 10 *neuron* pada *hidden layer* untuk menguji tingkat akurasi dari algoritma *training*, dimana performa estimasi dapat dilihat pada Tabel 1.

**Tabel 1.** Performa estimasi panjang antrian

Algoritma <i>Training</i>	MAE (m)	RMSE (m)	MAPE (%)
<i>Bayesian regularization</i>	6.2	7.8	9.6
<i>Levenberg-Marquardt backpropagation</i>	4.9	6.3	8.4
<i>Scaled conjugate gradient backpropagation</i>	7.7	8.5	11.9

*Levenberg-Marquardt backpropagation* memberikan tingkat akurasi estimasi yang paling tinggi. Hal ini ditunjukkan dengan nilai MAE, RMSE dan MAPE yang lebih kecil dibandingkan dengan dua algoritma lainnya. Maka, algoritma *Levenberg-Marquardt backpropagation* dipilih sebagai algoritma *training* dan digunakan untuk menentukan jumlah *neuron* pada *hidden layer*. Pengaruh jumlah *neuron*, antara 1 sampai dengan 20, terhadap tingkat akurasi estimasi kemudian dicari untuk menentukan jumlah *neuron* pada arsitektur ANN. Di bawah ini menunjukkan nilai MAE, MAPE dan RMSE untuk berbagai jumlah *neuron*.



Gambar 7. Performa ANN dengan menggunakan berbagai jumlah *neuron*  
 Gambar di atas menunjukkan terjadi peningkatan akurasi ketika jumlah *neuron* bertambah dari satu *neuron* menjadi 11 *neuron*. Namun, error meningkat ketika *neuron* berjumlah lebih dari 11. Maka pada studi ini digunakan 3 input, 11 *neuron* pada *hidden layer* dan 1 output dengan *Levenberg-Marquardt backpropagation* sebagai algoritma *training*. Model tersebut dapat mengestimasi panjang antrian kendaraan dengan MAE 3.8 m, RMSE sekitar 4.9 m dan MAPE 6%. Dengan nilai error yang kecil ini, dapat dikatakan bahwa model tersebut dapat mengestimasi panjang kendaraan dengan tingkat keakuratan yang baik.

## KESIMPULAN

Adapun kesimpulan yang dapat diperoleh dari hasil penelitian dan pembahasan yang diuraikan adalah sebagai berikut. Panjang antrian kendaraan pada lalu-lintas campuran bervariasi. Komposisi kendaraan merupakan faktor penting pembentuk panjang antrian kendaraan. Salah satu ruas kritis pada simpang bersinyal Muara Rapak, Balikpapan, diambil sebagai studi kasus pada penelitian ini. Ruas tersebut memiliki 2 lajur. Lajur 1 pada umumnya memiliki panjang antrian melebihi Lajur 2. Jika dibandingkan dengan jumlah kendaraan, maka Lajur 2 diisi oleh sepeda motor dengan komposisi yang tinggi. Dapat dikatakan bahwa walaupun sepeda motor komposisinya tinggi di Lajur 2, namun panjang antriannya lebih kecil dibandingkan Lajur 1-hal ini menunjukkan bahwa tumpukan sepeda motor antri dengan *gap* yang sangat kecil. LV termasuk mobil dan pick up, mendominasi Lajur 1 dan Sebagian kecil menempati Lajur 2. Kendaraan berat memiliki komposisi yang paling kecil dan pada umumnya menempati Lajur 1.

Lalu-lintas campuran merupakan sistem nonlinear yang kompleks, sehingga pada penelitian ini, panjang antrian diestimasi menggunakan pendekatan *machine learning* yaitu dengan mengaplikasikan ANN. Arsitektur ANN terdiri dari 3 input yaitu jumlah kendaraan MC, LV dan HV, 11 *neuron* pada *hidden layer* dan 1 output berupa panjang antrian. Algoritma *training* yang memberikan hasil terbaik adalah *Levenberg-Marquardt backpropagation*. Model ANN memiliki akurasi yang baik dalam mengestimasi panjang antrian yaitu dengan MAPE sebesar 6%.

## Ucapan Terima Kasih

Kami mengucapkan terima kasih atas pendanaan dari Politeknik Negeri Balikpapan dengan skema DIPA Kerjasama (31/PL32.13/SPK-LT/2022) dengan Dinas Perhubungan Kota Balikpapan sebagai mitra kerjasama penelitian.

## DAFTAR PUSTAKA

- Anusha, S., Vanajakshi, L., & Subramanian, S. C. (2022). Dynamical systems approach for queue and delay estimation at signalized intersections under mixed traffic conditions. *Transportation letters*, 14(6), 578-590.
- Chen, H.-H., Lin, Y.-B., Yeh, I.-H., Cho, H.-J., & Wu, Y.-J. (2022). Prediction of Queue Dissipation Time for Mixed Traffic Flows With Deep Learning. *IEEE Open Journal of Intelligent Transportation Systems*, 3, 267-277.
- Gao, K., Han, F., Dong, P., Xiong, N., & Du, R. (2019). Connected vehicle as a mobile sensor for real time queue length at signalized intersections. *Sensors*, 19(9), 2059.

- Gao, K., Huang, S., Han, F., Li, S., Wu, W., & Du, R. (2020). An integrated algorithm for intersection queue length estimation based on IoT in a mixed traffic scenario. *Applied Sciences*, 10(6), 2078.
- Gowri, A., & Sivanandan, R. (2015). Evaluation of right-turn lanes at signalized intersection in non-lane-based heterogeneous traffic using microscopic simulation model. *Transportation letters*, 7(2), 61-72.
- Harahap, E., Darmawan, D., Fajar, Y., Ceha, R., & Rachmiatie, A. (2019). Modeling and simulation of queue waiting time at traffic light intersection. In *Journal of Physics: Conference Series* (Vol. 1188, pp. 012001): IOP Publishing.
- Jammula, J. K., Bera, R., & Ravishankar, K. V. R. (2018). Travel time prediction modelling in mixed traffic conditions. *International Journal for Traffic and Transport Engineering*, 8(1), 135-147.
- Liu, D., An, C., Yasir, M., Lu, J., & Xia, J. (2022). A Machine Learning Based Method for Real-Time Queue Length Estimation Using License Plate Recognition and GPS Trajectory Data. *KSCE Journal of Civil Engineering*, 26(5), 2408-2419.
- Transportation Research Board. (2010). *Highway Capacity Manual (HCM 2000)*: National Research Council, Washington, DC, USA.
- Zhang, W., Zou, Y., Tang, J., Ash, J., & Wang, Y. (2016). Short-term prediction of vehicle waiting queue at ferry terminal based on machine learning method. *Journal of Marine Science and Technology*, 21(4), 729-741.