

PERAMALAN TRAFIK UNTUK ALOKASI BANDWIDTH JARINGAN SELULER 4G MENGGUNAKAN MODEL HYBRID ARIMA-LSTM

Rahmat Fuadi Syam¹, Firman Aziz²

Universitas Pancasakti Makassar^{1,2}
rahmat@unpacti.ac.id

This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.



Kata kunci:

lstm, bandwidth alokasi, time series.

Abstrak

Saat ini, ada beberapa teknik prediksi yang sangat membantu bisnis dalam meningkatkan efisiensi. Salah satunya adalah prediksi alokasi bandwidth. Diharapkan metode ini dapat membantu perusahaan telekomunikasi mengurangi biaya, terutama biaya transfer data dari setiap lokasi. Ketidakmampuan untuk mengelola bandwidth yang diperlukan saat ini adalah masalah umum bagi perusahaan telekomunikasi. Kadang-kadang, ada kekurangan bandwidth atau kelebihan bandwidth pada setiap BTS, yang dapat mengurangi keuntungan yang diperoleh perusahaan. Suatu sistem yang dapat mengatur dan memprediksi kebutuhan bandwidth masa depan diperlukan untuk menyelesaikan masalah tersebut. Dengan menggunakan data dari hasil monitoring bandwidth setiap cell, kami mengeksplorasi prediksi kebutuhan bandwidth pada penelitian ini. Data ini berupa baris waktu. Peneliti mengumpulkan data dari November 2019 hingga Januari 2020. Langkah pertama adalah melakukan simulasi prediksi dengan menggunakan metode LSTM. Setelah mencoba beberapa model LSTM model terbaik adalah LSTM (windows=100, 2 lapisan, 100 neuron), dengan hasil RMSE 387.693019. Peneliti menggunakan hasil model untuk melakukan eksperimen dengan model LTSM. Studi ini menemukan bahwa prediksi dalam waktu lima puluh jam menunjukkan tingkat akurasi yang tinggi.

Keywords:

The keywords chosen must reflect the concepts contained in the related article, with a total of 3-5 terms (horos).

Abstrack

Today, there are several prediction techniques that greatly help businesses in improving efficiency. One of them is bandwidth allocation prediction. It is expected that this method can help telecommunication companies reduce costs, especially data transfer costs from each location. The inability to manage the required bandwidth today is a common problem for telecommunication companies. Sometimes, there is a lack of bandwidth or excess bandwidth on each BTS, which can reduce the profit earned by the company. A system that can manage and predict future bandwidth requirements is needed to solve the problem. Using data from the bandwidth monitoring results of each cell, we explore the prediction of bandwidth requirements in this study. This data is in the form of time series. We collected data from November 2019 to January 2020. The first step is to simulate predictions using the LSTM method. After trying several LSTM models, the best model is LSTM (windows = 100, 2 layers, 100 neurons), with an RMSE of 387.693019. Researchers used the model results to conduct experiments with the LTSM model. The study found that the prediction within fifty hours showed a high level of accuracy.

Pendahuluan

Peran perusahaan telekomunikasi dalam menjaga kualitas jaringan yang dimiliki sangat penting dalam bidang teknologi, khususnya komunikasi. Akibatnya, diperlukan dasar perencanaan jaringan yang praktis (Y. Yu et al., 2013),(Kumar & Muthukumaravel, 2020) Saat ini, perhitungan penyediaan sumber daya bandwidth didasarkan pada besarnya trafik yang diukur pada saat peak time. yang mana tidak efisien dalam hal pemanfaatan sumber daya (Kim et al., 2011), sehingga mendorong penggunaan teknologi lain untuk menghitung bandwidth yang diperlukan. Teknik yang dikenal sebagai data mining dapat digunakan untuk menghitung bandwidth dengan mencari pola secara berkelompok (Larose & Larose, 2015). Penggunaan teknologi ini oleh perusahaan telekomunikasi akan sangat penting untuk mengantisipasi tingginya permintaan layanan mobile broadband di masa depan(Suryanegara et al., 2014). Hal ini didukung oleh banyaknya data yang dimiliki provider, tetapi belum dimanfaatkan

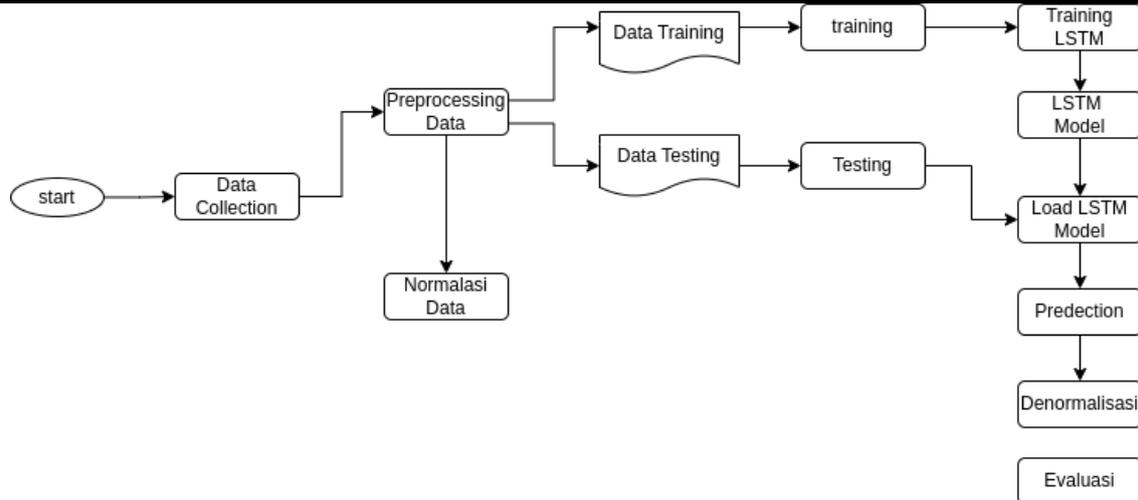
dengan baik. Data perusahaan sangat berbeda dalam rentang waktu dari beberapa detik hingga beberapa menit. Ini dapat dipantau dan digunakan sebagai peringatan gangguan di tempat kerja. Data jam dapat membantu merekayasa lalu lintas jaringan. di mana operator telekomunikasi memiliki kemampuan untuk mengubah sudut pandang mereka. Penelitian kami bergantung pada jaringan dari saluran sibuk ke saluran tidak terpakai untuk membuat prediksi.

Dua metode, machine learning dan statistik, digunakan untuk mempelajari literatur yang kami pelajari. Metode statistik yang menggunakan model autoregressive integrated moving average (ARIMA) dapat digunakan ketika sistem lalu lintas tidak terlalu kompleks dan dimensi data berskala kecil (Hamed et al., 1995) (Moayedi & Masnadi-Shirazi, 2008) (Peng et al., 2014). Model seasonal autoregressive integrated moving average (SARIMA) juga dapat digunakan ketika data mengandung faktor musiman atau kecenderungan untuk mengulang pola perilaku pergerakan selama periode musim tertentu (Williams & Hoel, 2003). Meskipun demikian, metode statistik memiliki kelemahan ketika dihadapkan pada permasalahan yang kompleks, Sehingga penggunaan metode Machine Learning dapat mengatasi kelemahan metode statistik pada dimensi data yang berskala besar dan data yang tidak linier. Namun, metode machine learning memiliki keterbatasan dalam hal hubungan spasial dan temporal dari pola trafik (Yang, 2013; Zhang et al., 2016; Zhao et al., 2020). Kedua metode ini mulai dikembangkan seiring dengan perkembangan teknologi untuk menyelesaikan masalah peramalan lalu lintas, terutama untuk hubungan spasial dan peramalan lalu lintas temporal. Metode machine learning seperti Deep Neural Networks (DNNs) dengan akurasi representasi yang menghasilkan metrik akurasi yang tinggi dan tingkat kesalahan yang rendah dalam menangani komponen trafik (Angarita-Zapata et al., 2019; Do et al., 2019; Ermagun & Levinson, 2018), Convolutional Neural Networks (CNNs) memiliki kemampuan untuk memodelkan hubungan trafik spasial, sementara Recurrent Neural Networks (RNNs) melakukan prediksi trafik jangka pendek dan terutama jangka panjang melalui pendekatan Long short term memory (LSTM) dan Gated Recurrent Unit (GRU) (Cui et al., 2018; H. Yu et al., 2017). Terlepas dari kenyataan bahwa ketiga pendekatan pembelajaran mesin tersebut dianggap sangat baik, mereka masih memiliki beberapa kekurangan. Misalnya, DNN terus melakukan seleksi data, terutama pada kekhususan data jalur; RNN lebih mudah menangkap hubungan rumit dan suara; dan CNN tidak dapat menampilkan gambar tiga dimensi, terutama pada hubungan spasial. Ruang Euclides. Metode statistik seperti ARIMA dan SARIMA cenderung tertinggal dibandingkan dengan perkembangan metode machine learning karena potensi pendekatan statistik untuk kasus peramalan trafik belum sepenuhnya dieksploitasi. Padahal pada beberapa kasus di luar kasus peramalan lalu lintas, seperti hybrid ARIMA pada kasus peramalan sumber daya air di Gaza Palestina (Abu Amra & Maghari, 2018), ARIMA yang digabungkan dengan LSTM pada kasus peramalan bahan makanan (Elmasdotter, 2018), dan LSTM dan ANN yang digabungkan dengan ARIMA dengan Moving Average (MA) pada kasus peramalan industri semen (Fradinata, 2014) menghasilkan performa yang memuaskan. Penelitian ini mengusulkan peramalan data runtun waktu lalu lintas dengan menggunakan metode ARIMA yang dikombinasikan dengan LSTM berdasarkan penelitian sebelumnya (Abu Amra & Maghari, 2018), yang menggunakan metode hybrid ARIMA-NN.

Sebaliknya, kami memilih metode hibrida ARIMA-LSTM untuk penelitian ini karena keakuratannya. Metode LSTM bekerja pada data non-linier, tetapi ARIMA bekerja pada data linier. Model (ARIMA) mengestimasi dan menyesuaikan data noise untuk mendapatkan residu dan hasil prediksi. Nilai residu melatih model LSTM dan kemudian digunakan sebagai LSTM untuk memperbaiki hasil prediksi ARIMA (Wang & Lou, 2019).

Metode

Proses peramalan sangat dipengaruhi oleh pola data deret waktu yang dihasilkan, sehingga diperlukan observasi awal untuk melakukan peramalan. Karena setiap metode statistik memiliki tahapan kerja yang berbeda, proses ini akan menganalisis berbagai jenis data. Proses peramalan digambarkan dalam Gambar 1 dibawah ini .



Gambar 1 Process LSTM

Tahap awal dalam penelitian ini dimulai dengan pengumpulan data yang relevan untuk memastikan model dapat memprediksi kebutuhan alokasi bandwidth dengan akurat. Data dikumpulkan dari berbagai sumber seperti nama cell, riwayat penggunaan bandwidth, serta atribut jaringan lainnya yang mendukung analisis lalu lintas jaringan. Sumber data dapat berupa file CSV, database internal, atau API yang memungkinkan pengumpulan data secara *real-time*, sehingga dapat mencakup variasi trafik pada berbagai waktu, seperti *peak time* dan *off-peak time*. Karena data mentah yang terkumpul tidak selalu memenuhi standar analisis yang diinginkan, tahap *preprocessing* data menjadi sangat penting untuk meningkatkan kualitas dan konsistensi data. Proses *preprocessing* mencakup beberapa sub-langkah: pertama, penghapusan data duplikat untuk menghindari bias akibat informasi yang berulang; kedua, penanganan data yang hilang dengan teknik imputasi seperti *mean imputation*, interpolasi, atau teknik *advanced* lain, untuk memastikan data yang hilang tidak memengaruhi hasil prediksi secara negatif. Langkah selanjutnya adalah pembersihan *outliers* atau data yang tidak sesuai dengan pola normal; *outliers* dapat dideteksi dan ditangani dengan metode seperti Z-score, IQR, atau *domain-specific rule*, tergantung pada distribusi data.

Setelah data bersih, dilakukan normalisasi untuk mengubah nilai fitur data ke dalam skala seragam, misalnya dalam rentang 0 hingga 1 atau -1 hingga 1. Teknik normalisasi sangat penting terutama jika model yang digunakan sensitif terhadap skala data, seperti model pembelajaran mesin berbasis jaringan saraf. Normalisasi memastikan setiap fitur berkontribusi secara proporsional terhadap proses pelatihan, mencegah fitur dengan rentang nilai lebih besar mendominasi hasil pelatihan. Setelah data dinormalisasi, langkah berikutnya adalah membagi dataset menjadi dua bagian utama: data training dan data testing. 60% sebagai data *training*, 20% sebagai data *validation*, dan 20% sisanya sebagai data *testing*. Data training digunakan untuk melatih model pembelajaran mesin sehingga model mampu mengenali pola-pola mendasar dalam data, sementara data testing hanya diakses setelah pelatihan untuk mengukur kemampuan generalisasi model. Pembagian ini penting untuk menghindari *overfitting*, di mana model mungkin memberikan hasil prediksi yang baik hanya pada data yang dikenal tetapi tidak akurat pada data baru.

Setelah pembagian data, model Long Short-Term Memory (LSTM) atau hybrid ARIMA-LSTM diterapkan untuk melatih model menggunakan data training. Model LSTM dipilih karena kemampuannya yang unggul dalam menangani data sekuensial, mengingat trafik jaringan menunjukkan pola yang bergantung pada waktu dan memiliki ketergantungan temporal yang kuat. Model hybrid ARIMA-LSTM juga disiapkan untuk menangani data linier dan non-linier dalam pola trafik; ARIMA mengatasi bagian linier dari data, sedangkan LSTM menutupi aspek non-linier, menghasilkan prediksi yang lebih akurat. Setelah model dilatih, tahap prediksi dilakukan dengan menggunakan data testing. Kinerja model dievaluasi berdasarkan metrik seperti Mean Squared Error (MSE) dan Root Mean Squared Error (RMSE). MSE mengukur rata-rata kuadrat selisih antara nilai prediksi dan nilai sebenarnya, memberikan gambaran tentang kesalahan secara keseluruhan,

sementara RMSE, sebagai akar kuadrat dari MSE, memberikan nilai kesalahan dalam satuan yang sama dengan data asli, yang sering kali lebih mudah diinterpretasikan. Evaluasi ini memberi gambaran yang akurat tentang efektivitas model dalam memprediksi kebutuhan bandwidth jaringan seluler 4G, memungkinkan penilaian yang lebih baik mengenai kemampuan model dalam memberikan solusi alokasi bandwidth yang optimal dan efisien.

Hasil dan Diskusi

Pada proses implementasi metode LSTM dalam penelitian ini, berbagai konfigurasi parameter diuji untuk mengeksplorasi konfigurasi model yang paling efektif dalam memprediksi kebutuhan alokasi bandwidth pada jaringan seluler 4G. Tahap pertama implementasi melibatkan pemilihan sliding window, yaitu ukuran jendela data historis yang digunakan sebagai input untuk memprediksi nilai selanjutnya. Sliding window memungkinkan model untuk menangkap pola-pola dalam jangka waktu tertentu. Dalam penelitian ini, dipilih tiga ukuran sliding window yang bervariasi, yaitu 50, 60, dan 100. Ukuran 50 dan 60 memungkinkan model untuk mempertimbangkan rentang waktu yang lebih pendek, sementara ukuran 100 mengizinkan analisis pola dalam jangka waktu yang lebih panjang.

Pada struktur arsitektur LSTM yang digunakan, model didesain dengan 1 input yang mewakili nilai historis dalam sliding window, serta menggunakan 2 lapisan tersembunyi (hidden layers) yang berfungsi untuk mengolah dan mengekstrak informasi yang lebih dalam dari data. Jumlah neuron dalam tiap lapisan disesuaikan pada beberapa konfigurasi, yaitu 50, 100, dan 150 neuron. Variasi jumlah neuron ini dilakukan untuk melihat bagaimana perubahan jumlah neuron memengaruhi kinerja model, karena semakin banyak neuron yang digunakan dapat meningkatkan kemampuan model untuk menangkap pola data yang kompleks, tetapi juga berpotensi meningkatkan risiko overfitting jika neuron yang digunakan terlalu banyak atau jika model menjadi terlalu kompleks dibandingkan dengan data yang tersedia.

Selain struktur arsitektur, proses pembagian data juga penting untuk memastikan bahwa model diuji secara valid dan tidak bergantung pada data yang sudah dikenalnya selama pelatihan. Oleh karena itu, data dibagi dengan komposisi 60% sebagai data training, 20% sebagai data validation, dan 20% sisanya sebagai data testing. Data training digunakan untuk melatih model, sedangkan data validation digunakan untuk memantau kinerja model selama pelatihan dan untuk menyesuaikan parameter agar tidak terjadi overfitting. Data testing disimpan terpisah dan baru digunakan setelah pelatihan selesai untuk menilai kinerja prediksi akhir model terhadap data baru yang tidak pernah dilihat sebelumnya.

Dalam mencari model terbaik, penelitian ini melakukan serangkaian uji coba dengan berbagai kombinasi sliding window dan jumlah neuron pada kedua lapisan tersembunyi. Setiap konfigurasi diuji dan hasilnya dicatat, terutama dalam hal akurasi prediksi yang diukur menggunakan Mean Squared Error (MSE) dan Root Mean Squared Error (RMSE) pada data validation. MSE mengukur seberapa besar kesalahan kuadrat rata-rata antara nilai prediksi dan nilai aktual, sementara RMSE, sebagai akar dari MSE, memberikan gambaran dalam satuan yang sama dengan data asli, yang lebih mudah diinterpretasikan dalam konteks performa prediksi.

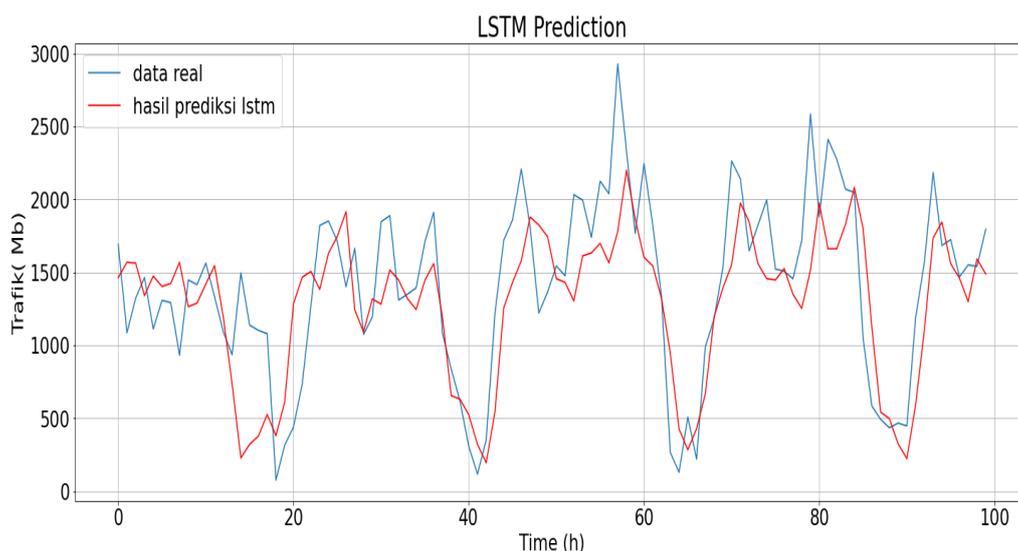
Tabel 1 menyajikan hasil lengkap dari setiap konfigurasi yang diuji, menunjukkan variasi kinerja model berdasarkan perubahan sliding window dan jumlah neuron. Dengan hasil ini, analisis dilakukan untuk menentukan kombinasi parameter yang memberikan kinerja terbaik, yaitu yang menghasilkan nilai MSE dan RMSE paling rendah pada data validation, sekaligus menunjukkan kemampuan model untuk melakukan generalisasi. Konfigurasi terbaik dari model LSTM ini kemudian dibandingkan dengan metode ARIMA dan hybrid ARIMA-LSTM untuk melihat perbedaan kinerja dan menilai efektivitas LSTM dalam prediksi trafik jaringan 4G. Hasil perbandingan ini akan menjadi dasar dalam memilih metode yang paling akurat dan sesuai untuk peramalan alokasi bandwidth di jaringan seluler.

Tabel 1 LSTM model

No	Sliding Window	Layer	Neuron	MSE	RMSE
1	50	2	50	230400.169	480.000176
2	50	2	100	234081.585	483.819786
3	50	2	150	220050.330	469.095224
4	100	2	50	223364.352	472.614380
5	100	2	100	217779.011	466.667988
6	100	2	150	224141.665	473.436020

Setelah serangkaian percobaan terhadap parameter model LSTM, didapatkan konfigurasi terbaik untuk prediksi kebutuhan alokasi bandwidth, yaitu model dengan ukuran *sliding window* sebesar 100, dua lapisan tersembunyi, dan 100 neuron. Konfigurasi ini menunjukkan performa terbaik dengan nilai *Root Mean Squared Error* (RMSE) sebesar 466.667988, yang mengindikasikan tingkat akurasi yang lebih tinggi dibandingkan konfigurasi lainnya. Tabel 1 memperlihatkan bahwa peningkatan ukuran *sliding window* dari 50 menjadi 100 memberikan peningkatan akurasi, menunjukkan bahwa rentang jendela data yang lebih panjang memungkinkan model untuk menangkap pola temporal yang lebih kompleks dan memberikan prediksi yang lebih akurat.

Selain itu, grafik prediksi yang ditampilkan pada Gambar 2 memperlihatkan perbandingan antara hasil prediksi model LSTM dan data aktual, di mana model dapat mengikuti tren data aktual dengan cukup baik. Grafik ini menegaskan bahwa pemilihan *sliding window* 100 memberikan representasi yang lebih mendetail terhadap pola trafik jaringan, yang menjadi krusial dalam konteks prediksi alokasi bandwidth untuk memenuhi kebutuhan jaringan seluler yang dinamis.



Gambar 2. Prediski LSTM

Kesimpulan

Kesimpulan dari penelitian ini menunjukkan bahwa metode LSTM memberikan hasil prediksi yang lebih akurat untuk peramalan penggunaan trafik pada sel BTS dibandingkan dengan metode ARIMA, sebagaimana terlihat dari nilai RMSE yang lebih rendah. Dengan keunggulannya dalam menangkap

pola data sekuensial, LSTM terbukti efektif dalam memprediksi kebutuhan bandwidth secara lebih tepat, yang dapat menjadi dasar dalam pengelolaan kapasitas jaringan dan alokasi sumber daya pada jaringan seluler. Penelitian ini menegaskan bahwa model LSTM mampu meramalkan penggunaan trafik dengan baik, meskipun demikian, terdapat berbagai variabel tambahan yang dapat memengaruhi kebutuhan bandwidth, seperti jumlah pengguna, jenis aplikasi yang digunakan, serta waktu akses pengguna. Di masa mendatang, kami berencana mengembangkan model yang lebih komprehensif dengan mempertimbangkan variabel-variabel tersebut sebagai parameter tambahan untuk meningkatkan akurasi prediksi dan kemampuan model dalam menyesuaikan dengan kondisi jaringan yang lebih kompleks. Hasil penelitian ini diharapkan dapat membantu operator telekomunikasi dalam pengelolaan bandwidth yang lebih efisien sesuai dengan kebutuhan trafik jaringan.

Referensi

- Abu Amra, I. A. S., & Maghari, A. Y. A. (2018). Forecasting Groundwater Production and Rain Amounts Using ARIMA-Hybrid ARIMA: Case Study of Deir El-Balah City in Gaza. *Proceedings - 2018 International Conference on Promising Electronic Technologies, ICPET 2018*, 135–140. <https://doi.org/10.1109/ICPET.2018.00031>
- Angarita-Zapata, J. S., Masegosa, A. D., & Triguero, I. (2019). A Taxonomy of Traffic Forecasting Regression Problems from a Supervised Learning Perspective. *IEEE Access*, 7, 68185–68205. <https://doi.org/10.1109/ACCESS.2019.2917228>
- Cui, Z., Ke, R., & Wang, Y. (2018). *Deep Bidirectional and Unidirectional LSTM Recurrent Neural Network for Network-wide Traffic Speed Prediction*. 1–11. <http://arxiv.org/abs/1801.02143>
- Do, L. N. N., Taherifar, N., & Vu, H. L. (2019). Survey of neural network-based models for short-term traffic state prediction. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(1), 1–24. <https://doi.org/10.1002/widm.1285>
- Elmasdotter, A. (2018). *LSTM and ARIMA for sales A comparative study between LSTM and ARIMA for sales forecasting in retail*.
- Ermagun, A., & Levinson, D. (2018). Spatiotemporal traffic forecasting: review and proposed directions. *Transport Reviews*, 38(6), 786–814. <https://doi.org/10.1080/01441647.2018.1442887>
- Fradinata, E. (2014). *ANN, ARIMA and MA Timeseries Model for Forecasting in Cement Manufacturing Industry*. 39–44.
- Hamed, M., Al-Masaeid, H., & Sai, Z. (1995). SHORT-TERM PREDICTION OF TRAFFIC VOLUME IN URBAN ARTERIALS By Mohammad M. Hamed,1 Hashem R. Al-Masaeid,2 and Zahi M. Bani Said 3. *J. Transp. Eng, I*(June), 249–254.
- Kim, H. W., Lee, J. H., Choi, Y. H., Chung, Y. U., & Lee, H. (2011). Dynamic bandwidth provisioning using ARIMA-based traffic forecasting for Mobile WiMAX. *Computer Communications*, 34(1), 99–106. <https://doi.org/10.1016/j.comcom.2010.08.008>
- Kumar, V. S., & Muthukumaravel, A. (2020). *Seasonal forecasting of mobile data traffic in GSM networks with linear trend*. 23(3), 469–474.

- Larose, D. T., & Larose, C. D. (2015). Data Mining and Predictive Analytics (Wiley Series on Methods and Applications in Data Mining). *Wiley Series*, 794. <https://doi.org/10.1007/s13398-014-0173-7.2>
- Moayedi, H. Z., & Masnadi-Shirazi, M. A. (2008). Arima model for network traffic prediction and anomaly detection. *Proceedings - International Symposium on Information Technology 2008, ITSIM*, 3, 6–11. <https://doi.org/10.1109/ITSIM.2008.4631947>
- Peng, Y., Lei, M., Li, J. B., & Peng, X. Y. (2014). A novel hybridization of echo state networks and multiplicative seasonal ARIMA model for mobile communication traffic series forecasting. *Neural Computing and Applications*, 24(3–4), 883–890. <https://doi.org/10.1007/s00521-012-1291-9>
- Suryanegara, M., Ramadhan, A., Akbar, A. K., & Asvial, M. (2014). The forecasting model of 4G LTE implementation in Indonesia. *ICMIT 2014 - 2014 IEEE International Conference on Management of Innovation and Technology*, 1, 461–466. <https://doi.org/10.1109/ICMIT.2014.6942471>
- Wang, Z., & Lou, Y. (2019). Hydrological time series forecast model based on wavelet de-noising and ARIMA-LSTM. *Proceedings of 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference, ITNEC 2019, Itnec*, 1697–1701. <https://doi.org/10.1109/ITNEC.2019.8729441>
- Williams, B. M., & Hoel, L. A. (2003). Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: Theoretical basis and empirical results. *Journal of Transportation Engineering*, 129(6), 664–672. [https://doi.org/10.1061/\(ASCE\)0733-947X\(2003\)129:6\(664\)](https://doi.org/10.1061/(ASCE)0733-947X(2003)129:6(664))
- Yang, S. (2013). On feature selection for traffic congestion prediction. *Transportation Research Part C: Emerging Technologies*, 26, 160–169. <https://doi.org/10.1016/j.trc.2012.08.005>
- Yu, H., Wu, Z., Wang, S., Wang, Y., & Ma, X. (2017). Spatiotemporal recurrent convolutional networks for traffic prediction in transportation networks. *Sensors (Switzerland)*, 17(7), 1–16. <https://doi.org/10.3390/s17071501>
- Yu, Y., Song, M., Fu, Y., & Song, J. (2013). Traffic prediction in 3G mobile networks based on multifractal exploration. *Tsinghua Science and Technology*, 18(4), 398–405. <https://doi.org/10.1109/TST.2013.6574678>
- Zhang, J., Zheng, Y., Qi, D., Li, R., & Yi, X. (2016). *DNN-Based Prediction Model for Spatio-Temporal Data*.
- Zhao, L., Song, Y., Zhang, C., Liu, Y., Wang, P., Lin, T., Deng, M., & Li, H. (2020). T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction. *IEEE Transactions on Intelligent Transportation Systems*, 21(9), 3848–3858. <https://doi.org/10.1109/TITS.2019.2935152>