

Peramalan Penggunaan *Bandwidth* Internet dengan Pendekatan *Time Series* ARIMA Menggunakan Optimasi Parameter

Rahmawan Bagus Trianto^{1*}, Kukuh Muhammad², Joko Purwanto³, Adlan Nugroho⁴

^{1,2,3,4}Politeknik Negeri Cilacap

¹rahmawanbagustrianto@pnc.ac.id, ²kukuhmuhammad@pnc.ac.id, ³jokopurwanto@pnc.ac.id

⁴adlannugroho@pnc.ac.id

Abstrak

Pengelolaan *bandwidth* internet yang efisien merupakan tantangan penting dalam administrasi jaringan, terutama pada institusi dengan tingkat penggunaan data tinggi. Fluktuasi trafik internet yang signifikan dapat menyebabkan *bottleneck* dan penurunan performa layanan. Oleh karena itu, kemampuan untuk melakukan estimasi kebutuhan *bandwidth* secara akurat menjadi krusial. Penelitian ini mengimplementasikan metode peramalan deret waktu ARIMA (*Autoregressive Integrated Moving Average*) untuk memprediksi penggunaan *bandwidth* pada jaringan lokal selama periode satu bulan. Data menggunakan dataset *dummy* berjumlah 100 baris yang bertujuan untuk menganalisis performa model ARIMA dan dianalisis menggunakan Python dengan pustaka statistik seperti *Pandas*, *Statsmodels*, dan *Matplotlib*. Model ARIMA dipilih berdasarkan hasil uji stasioneritas dan analisis ACF/PACF. Evaluasi performa dilakukan menggunakan RMSE. Hasil penelitian menunjukkan bahwa model ARIMA(4,2,7) memberikan akurasi prediksi yang tinggi dengan nilai RMSE sebesar 3.276. Estimasi ini dapat membantu administrator jaringan dalam merencanakan kapasitas secara proaktif, menghindari gangguan layanan akibat kelebihan beban, serta mendukung pengambilan keputusan berbasis data dalam manajemen jaringan.

Kata Kunci: ARIMA, peramalan, *time series*, *bandwidth*

Abstract

Efficient internet bandwidth management is a critical challenge in network administration, especially in institutions with high data usage. Significant fluctuations in internet traffic can cause bottlenecks and a decline in service performance. Therefore, the ability to accurately estimate bandwidth requirements becomes crucial. This research implements the Autoregressive Integrated Moving Average (ARIMA) time series forecasting method to predict bandwidth usage on a local network over a one-month period. The data uses a dummy dataset of 100 rows aimed at analyzing the performance of the ARIMA model and is analyzed using Python with statistical libraries such as Pandas, Statsmodels, and Matplotlib. The ARIMA model was selected based on the results of the stationarity test and ACF/PACF analysis. Performance evaluation was conducted using RMSE. The research results show that the ARIMA(4,2,7) model provides high prediction accuracy with an RMSE value of 3.276. This estimation can assist network administrators in proactively planning capacity, avoiding service disruptions due to overload, and supporting data-driven decision-making in network management.

Keywords: ARIMA, forecasting, *time series*, *bandwidth*

1. Pendahuluan

Dalam era digital saat ini, internet telah menjadi tulang punggung operasional bagi semua kalangan, seperti perusahaan, instansi pemerintah, sekolah, pariwisata dan lainnya (Li et al., 2021). Ketergantungan yang semakin meningkat pada aplikasi berbasis *cloud*, komunikasi daring, dan transfer data dalam jumlah besar menuntut pengelolaan *bandwidth* internet yang efisien (Shayea et al., 2022).

Prediksi yang akurat atas kebutuhan *bandwidth* menjadi sangat penting untuk berbagai alasan, termasuk perencanaan kapasitas yang efektif, optimasi alokasi sumber daya jaringan, dan memastikan kualitas layanan (QoS) yang memadai bagi pengguna (Prajam et al., 2022).


Model *time series* telah terbukti sebagai alat yang ampuh untuk menganalisis dan memprediksi data yang bervariasi seiring waktu (Aditya Satrio et al., 2021; Gencer & Başçiftçi,

2021). Pendekatan berbasis ARIMA, diperkenalkan (Box & Jenkins, 1976) dan dikembangkan lebih lanjut oleh (Brockwell & Davis, 1991; Chatfield, 2000) telah menjadi model dasar yang banyak digunakan dalam berbagai konteks peramalan *time series*. Di antara model-model *time series* yang tersedia, model *Autoregressive Integrated Moving Average* (ARIMA) secara luas diakui karena fleksibilitas dan efektivitasnya dalam menangani berbagai pola data (Ning et al., 2022).

Penelitian ini bertujuan untuk menerapkan model ARIMA dalam konteks estimasi penggunaan *bandwidth* internet yang dapat diterapkan di mana saja seperti di lingkungan perusahaan, lingkungan sekolah/sector pendidikan, pemerintahan, maupun swasta (Mendoza, 2024; Sahu & Tripathi, 2025). Fokus utama adalah pada optimasi parameter model ARIMA untuk mencapai estimasi terbaik. Dengan memanfaatkan metode *auto_arima*, penelitian ini berupaya untuk mengotomatiskan proses pemilihan parameter, yang seringkali menjadi tantangan dalam pemodelan ARIMA tradisional. Selain itu, penelitian ini memberikan analisis komprehensif tentang metodologi, hasil, dan implikasi praktis dari temuan tersebut untuk manajemen *bandwidth* internet yang lebih baik.

2. Metode Penelitian

Penelitian ini mengadopsi pendekatan kuantitatif untuk mengembangkan dan mengevaluasi model *time series forecasting* penggunaan *bandwidth* internet. Berikut gambaran urutan metode penelitian kali ini.



Gambar 1. Metode Penelitian

Gambar 1. di atas merupakan metodologi penelitian yang melibatkan beberapa tahap utama:

2.1. Pembuatan Data Sintesis

Penelitian ini menggunakan data sintesis yang dihasilkan untuk mensimulasikan pola penggunaan *bandwidth* harian. Dataset sintesis ini dibuat dengan mempertimbangkan faktor-faktor seperti tren pertumbuhan, variasi musiman mingguan, dan noise acak untuk mencerminkan dinamika penggunaan *bandwidth* di dunia nyata. Pembuatan dataset dilakukan menggunakan *library Python* seperti *pandas* dan *numpy*. Data sintesis ini didapatkan sebanyak 100 baris data.

2.2. Pembagian Data

Dalam metodologi penelitian ini, dataset sintesis yang dihasilkan dibagi menjadi dua subset yang berbeda: data latih (*training data*) dan data uji (*testing data*). Pembagian ini merupakan langkah krusial dalam proses pengembangan dan evaluasi model *forecasting* (Saha et al., 2024). Data latih memiliki peran utama dalam membangun fondasi model ARIMA. Data ini digunakan untuk menentukan parameter model, seperti orde autoregresif (p), orde integrasi (d), dan orde rata-rata bergerak (q), serta untuk melatih model agar dapat mengenali pola dan tren yang ada dalam data historis. Dengan kata lain, data latih "mengajarkan" model bagaimana data penggunaan *bandwidth* di masa lalu berperilaku.

Sementara data latih digunakan untuk membangun model, data uji memiliki fungsi yang berbeda dan sama pentingnya. Data uji terdiri dari subset data yang tidak digunakan selama proses pelatihan model. Setelah model ARIMA dilatih dengan data latih, data uji disajikan kepada model untuk menguji kemampuannya dalam membuat prediksi pada data yang belum pernah dilihat sebelumnya. Ini meniru skenario dunia nyata di mana model akan digunakan untuk memprediksi penggunaan *bandwidth* di masa depan. Dengan membandingkan prediksi model dengan nilai aktual dalam data uji, kita dapat mengukur seberapa baik

model tersebut melakukan generalisasi ke data baru (Di Mauro et al., 2024).

Pembagian data menjadi data latih dan data uji memungkinkan penilaian yang objektif terhadap kemampuan generalisasi model ARIMA. Generalisasi adalah kemampuan model untuk membuat prediksi yang akurat pada data baru atau yang belum dilihat sebelumnya (Zhang et al., 2018). Model yang memiliki kemampuan generalisasi yang baik mampu menangkap pola yang relevan dalam data dan tidak hanya menghafal data latih. Ini penting untuk memastikan bahwa model tersebut berguna untuk *forecasting* penggunaan bandwidth di masa depan secara andal. Jika model hanya berkinerja baik pada data latih tetapi buruk pada data uji, ini mungkin mengindikasikan *overfitting*, di mana model terlalu kompleks dan menangkap *noise* dalam data latih daripada pola yang sebenarnya. Pembagian data latih dan data uji pada penelitian ini menggunakan rasio 80% dan 20% untuk masing-masingnya.

2.3. Pemodelan ARIMA

Model ARIMA diterapkan pada data latih untuk menangkap pola temporal dalam penggunaan *bandwidth*. Parameter model ARIMA, yang dilambangkan dengan (p, d, q), menentukan orde komponen autoregresif (AR), orde integrasi (I), dan orde *moving average* (MA) (Ning et al., 2022). Persamaan untuk menghitung ARIMA adalah sebagai berikut.

Notasi umum ARIMA (p, d, q):

$$Y_t' = \phi_1 Y_t - 1' + \phi_2 Y_t - 2' + \dots + \phi_p Y_t - p' + \theta_1 e_t - 1 + \theta_2 e_t - 2 + \dots + \theta_q e_t - q + e_t \quad (1)$$

Dengan:

Y_t' : data setelah *differencing* sebanyak d kali (jika $d=0$, maka $Y_t' = Y_t$)

ϕ : koefisien AR (*autoregressive*)

θ : koefisien MA (*moving average*)

e_t : *white noise* (*error*)

Komponen *differencing*:

Jika $d = 1$, maka lakukan *first order differencing*:

$$Y_t' = Y_t - Y_{t-1} \quad (2)$$

Jika $d = 2$, maka:

$$Y_t'' = (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) = Y_t - 2Y_{t-1} + Y_{t-2} \quad (3)$$

Untuk AR (1):

$$Y_t = \phi_1 Y_{t-1} + e_t \quad (4)$$

Untuk AR (p):

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t \quad (5)$$

Untuk MA (1):

$$Y_t = e_t + \theta_1 e_{t-1} \quad (6)$$

Untuk MA (q):

$$Y_t = e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (7)$$

2.4. Optimasi Parameter

Untuk mengoptimalkan parameter model ARIMA, penelitian ini memanfaatkan fungsi *auto_arima* dari *library pmdarima* di *Python*. Fungsi *auto_arima* secara otomatis mencari kombinasi parameter (p, d, q) yang optimal berdasarkan kriteria informasi, seperti *Akaike Information Criterion* (AIC) atau *Bayesian Information Criterion* (BIC). Pada tahap ini juga akan dibandingkan dengan optimasi secara manual menggunakan konsep *looping* sehingga didapatkan parameter terbaik di antara kedua cara ini.

2.5. Evaluasi Performa Model

Performa model ARIMA dievaluasi menggunakan Root Mean Squared Error (RMSE) pada data uji. RMSE mengukur rata-rata besarnya kesalahan antara nilai prediksi dan nilai aktual, dengan nilai yang lebih rendah menunjukkan akurasi prediksi yang lebih baik (Shayea et al., 2022). Untuk menghitung RMSE dapat menggunakan persamaan berikut.

$$RMSE = \sqrt{\left(\frac{1}{n}\right) \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (8)$$

Dimana:

Y_t : nilai aktual pada waktu ke- t

$\hat{Y}_t$: nilai hasil prediksi pada waktu ke- t

n : jumlah total observasi

3. Hasil Penelitian dan Pembahasan

Pada bagian hasil penelitian ini akan dijelaskan sebagai berikut termasuk pembahasannya.

3.1. Hasil Optimasi Parameter ARIMA

Proses optimasi parameter menggunakan *auto_arima* berhasil mengidentifikasi kombinasi parameter ARIMA (p, d, q) yang sesuai untuk data penggunaan *bandwidth* internet. Parameter optimal yang ditemukan mencerminkan karakteristik spesifik dari data, seperti tren dan pola musiman. Penggunaan *auto_arima* menghasilkan parameter ARIMA (p, d, q) terbaik dengan nilai $p=4, d=1$ dan $q=1$ dengan nilai RMSE sebesar 5.0397.

Selain itu, dengan menggunakan optimasi parameter ARIMA menggunakan konsep *looping* (semi otomatis) di mana nilai p diberikan rentang antara 0 sampai 9, nilai d diberikan rentang nilai antara 0 sampai 5 dan q diberikan rentang nilai antara 0 sampai 9 menghasilkan luaran yang lebih baik dengan parameter ARIMA (p, d, q) masing-masing 4, 2, 7 dengan nilai RMSE sebesar 3.28.

3.2. Performa Model ARIMA

Model ARIMA yang dioptimalkan menunjukkan performa peramalan yang baik pada data uji, yang ditunjukkan oleh nilai RMSE yang rendah. Hasil ini menunjukkan bahwa model secara efektif menangkap pola temporal yang relevan dalam data penggunaan *bandwidth* internet dan membuat prediksi yang akurat untuk periode waktu yang belum dilihat. Model ARIMA dengan menggunakan *auto_arima* didapatkan nilai $p=4, d=1$ dan $q=1$ dengan nilai RMSE sebesar 5.0397 dengan pendekatan *auto_arima* dan 3.28 dengan pendekatan *looping* dengan batasan setiap parameternya.

Model ARIMA yang dioptimalkan dalam penelitian ini menunjukkan performa peramalan yang dapat diinterpretasikan sebagai 'cukup baik' pada data uji. Penting untuk dicatat bahwa interpretasi nilai RMSE sangat kontekstual; tidak ada nilai universal yang secara inheren dianggap

'baik' atau 'buruk'. RMSE mengukur rata-rata besarnya kesalahan prediksi model, dan nilai 5.0397 menunjukkan bahwa, secara rata-rata, prediksi model menyimpang sekitar 5.0397 unit dan 3.28 unit dari nilai aktual dalam data uji.

3.3. Pembahasan

Temuan penelitian ini konsisten dengan penelitian sebelumnya yang menyoroti efektivitas model ARIMA dalam *time series forecasting*. Optimasi parameter model memainkan peran penting dalam mencapai akurasi prediksi yang tinggi. Metode *auto_arima* menyediakan pendekatan otomatis dan efisien untuk menemukan parameter model ARIMA yang optimal, mengurangi kebutuhan akan pemilihan parameter manual yang memakan waktu dan subjektif. Berikut hasil optimasi parameter pada ARIMA dengan menggunakan *auto_arima* dengan melihat nilai AIC.

Tabel 1. Hasil Model Auto ARIMA

ARIMA (p,d,q)	Inter cept	AIC	Time (sec)
	Ya		
ARIMA(0,1,0)	Ya	574.412	0.02
	Ya		
ARIMA(0,1,1)	Ya	576.324	0.07
	Ya	inf	
ARIMA(0,1,2)	Ya	inf	0.25
	Ya	inf	
ARIMA(0,1,3)	Ya	inf	0.42
	Ya	inf	
ARIMA(0,1,4)	Ya		0.44
	Ya		
ARIMA(0,1,5)	Ya	535.438	2.10
	Ya		
ARIMA(1,1,0)	Ya	576.347	0.09
	Ya	inf	
ARIMA(1,1,1)	Ya	inf	0.26
	Ya	inf	
ARIMA(1,1,2)	Ya	inf	0.33
	Ya	inf	
ARIMA(1,1,3)	Ya	inf	0.54
	Ya	inf	
ARIMA(1,1,4)	Ya		0.61
	Ya		
ARIMA(2,1,0)	Ya	577.241	0.11
	Ya	inf	
ARIMA(2,1,1)	Ya		0.32
	Ya		
ARIMA(2,1,2)	Ya	528.924	0.66
	Ya	inf	
ARIMA(2,1,3)			0.59


	Ya		
ARIMA(3,1,0)		568.688	0.16
	Ya	inf	
ARIMA(3,1,1)			0.43
	Ya		
ARIMA(3,1,2)		519.227	0.31
	Ya		
ARIMA(4,1,0)		535.750	0.42
	Ya		
ARIMA(4,1,1)		512.912	0.28
	Ya		
ARIMA(5,1,0)		523.122	0.55

Tabel 1 di atas menunjukkan nilai parameter ARIMA(4,1,1) menghasilkan nilai AIC terendah, yaitu 512.912 dibandingkan dengan parameter lainnya. Sementara itu, ketika menggunakan konsep *looping* dengan pemberian rentang nilai masing-masing p diberikan rentang antara 0 sampai 9, nilai d diberikan rentang nilai antara 0 sampai 5 dan q diberikan rentang nilai antara 0 sampai 9 dapat dilihat pada tabel 2 berikut.

Tabel 2. Hasil Model Semi Otomatis ARIMA


ARIMA (p,d,q)	RMSE
ARIMA(4, 2, 7)	3.276
ARIMA(3, 2, 5)	3.288
ARIMA(4, 2, 6)	3.334
ARIMA(4, 2, 8)	3.404
ARIMA(5, 2, 7)	3.533
ARIMA(6, 2, 7)	3.646
ARIMA(5, 2, 6)	3.718
ARIMA(7, 2, 8)	3.780
ARIMA(6, 2, 8)	3.798
ARIMA(6, 1, 4)	3.934

Tabel 2 di atas merupakan 10 data terbaik hasil pencarian model ARIMA dengan parameter menggunakan teknik *looping* seperti yang telah dijelaskan sebelumnya. Teknik ini menghasilkan model terbaik dengan parameter ARIMA(4, 2, 7) dengan RMSE 3.276. Adapun perbandingan dari kedua teknik ini jika digambarkan dalam grafik dapat dilihat pada gambar 2 dan 3 berikut ini.



Gambar 2. Grafik Model Auto ARIMA (4, 1, 1)

Gambar 2 di atas merupakan grafik *forecasting* menggunakan model ARIMA (4, 1, 1) ditandai dengan grafik garis warna hijau. Sedangkan garis warna merah merupakan prediksi dari model ARIMA dan dibandingkan dengan data actual. Nampak bahwa antara data asli dan prediksi masih terdapat *gap* atau perbedaan yang cukup signifikan. Hal ini dikarenakan dari nilai RMSE yang masih di angka 5.0397. Pada model ARIMA semi otomatis dapat dilihat pada gambar 3 berikut ini.



Gambar 3. Grafik Model Semi Auto ARIMA

Gambar 3 di atas menunjukkan grafik *forecasting* yang ditandai dengan grafik warna oranye dan prediksi dari data asli yang ditandai dengan grafik berwarna ungu. Dengan model ARIMA (4, 2, 7) yang memiliki nilai RMSE lebih kecil dibanding dengan model sebelumnya, yaitu 3.276, nampak bahwa hasil prediksi memiliki *gap* yang lebih besar dibandingkan dengan *auto_arima*, namun *forecasting* yang dihasilkan cenderung mengikuti data historis yang telah ada sebelumnya.

RMSE *forecasting* yang dicapai oleh model ARIMA yang dioptimalkan memiliki implikasi praktis yang signifikan untuk manajemen *bandwidth* internet. Prediksi yang akurat memungkinkan perencanaan kapasitas

yang lebih baik, memastikan bahwa sumber daya jaringan yang memadai tersedia untuk memenuhi kebutuhan pengguna. Selain itu, prediksi dapat memfasilitasi optimasi alokasi *bandwidth*, memungkinkan administrator jaringan untuk mendistribusikan *bandwidth* secara efisien di berbagai aplikasi dan layanan.

4. Kesimpulan

Penelitian ini telah menunjukkan penerapan yang berhasil dari model ARIMA untuk memperkirakan penggunaan *bandwidth* internet. Penggunaan metode *auto_arima* memungkinkan optimasi parameter model secara otomatis, menghasilkan peningkatan akurasi prediksi. Selain itu, optimasi dengan teknik semi otomatis dengan teknik *looping* dengan rentang nilai yang telah ditentukan menunjukkan performansi yang lebih baik. Temuan penelitian ini memberikan wawasan yang berharga untuk manajemen *bandwidth* yang efektif, memungkinkan instansi atau pengelola jaringan untuk mengoptimalkan sumber daya jaringan mereka dan memastikan kualitas layanan yang memadai.

Penelitian di masa depan dapat mengeksplorasi beberapa arah potensial. Pertama, memasukkan faktor-faktor eksternal, seperti tren bisnis, aktivitas karyawan, atau peristiwa tertentu, ke dalam model prediksi dapat lebih meningkatkan akurasi prediksi. Kedua, membandingkan performa model ARIMA dengan model *time series* lainnya, seperti model *Seasonal ARIMA* (SARIMA) atau model *machine learning* lainnya, dapat memberikan pemahaman yang lebih komprehensif tentang kekuatan dan kelemahan relatif mereka dalam konteks estimasi *bandwidth*. Terakhir, mengembangkan sistem pendukung keputusan berbasis prediksi yang mengotomatiskan alokasi *bandwidth* internet berdasarkan perkiraan penggunaan di masa depan dapat semakin mengoptimalkan sumber daya jaringan dan meningkatkan efisiensi operasional.

5. Daftar Pustaka

Aditya Satrio, C. B., Darmawan, W., Nadia, B. U., & Hanafiah, N. (2021). Time series analysis and forecasting of coronavirus disease in Indonesia using ARIMA model and PROPHET. *5th International Conference on Computer Science and Computational*

Intelligence 2020, 179(2020), 524–532. <https://doi.org/10.1016/j.procs.2021.01.036>

Box, G. E. P., & Jenkins, G. M. (1976). *Time Series Analysis Forecasting and Control* (Revised Ed). Holden-Day.

Brockwell, P. J., & Davis, R. A. (1991). Time Series: Theory and Methods. In *Library of Congress Cataloging-in-Publication Data* (2nd ed.). Springer Science+Business Media. <https://doi.org/10.2307/2982983>

Chatfield, C. (2000). Time-Series Forecasting. In *Library of Congress Cataloging-in-Publication Data*. Chapman & C Hall/CRC. https://doi.org/10.1007/978-3-031-28113-6_6

Di Mauro, M., Galatro, G., Postiglione, F., Song, W., & Liotta, A. (2024). Hybrid learning strategies for multivariate time series forecasting of network quality metrics. *Computer Networks*, 243(March), 110286. <https://doi.org/10.1016/j.comnet.2024.110286>

Gencer, K., & Başçiftçi, F. (2021). Time series forecast modeling of vulnerabilities in the android operating system using ARIMA and deep learning methods. *Sustainable Computing: Informatics and Systems*, 30(May 2020), 1–11. <https://doi.org/10.1016/j.suscom.2021.100515>

Li, X., Law, R., Xie, G., & Wang, S. (2021). Review of tourism forecasting research with internet data. *Tourism Management*, 83(October 2020). <https://doi.org/10.1016/j.tourman.2020.104245>

Mendoza, A. P. (2024). Dengue incidence forecasting model in Magalang, Pampanga using time series analysis. *Informatics in Medicine Unlocked*, 44(October 2023), 101439. <https://doi.org/10.1016/j.imu.2023.101439>

Ning, Y., Kazemi, H., & Tahmasebi, P. (2022). A comparative machine learning study for time series oil production forecasting: ARIMA, LSTM, and Prophet. *Computers and Geosciences*, 164(March), 1–11. <https://doi.org/10.1016/j.cageo.2022.105126>

Prajam, S., Wechtaisong, C., & Khan, A. A. (2022). Applying Machine Learning Approaches for Network Traffic Forecasting. *Indian Journal of Computer Science and Engineering*, 13(2), 324–335. <https://doi.org/10.21817/indjcse/2022/v13i2/221302188>

Saha, S., Haque, A., & Sidebottom, G. (2024). Multi-Step Internet Traffic Forecasting

- Models with Variable Forecast Horizons for Proactive Network Management †. *Sensors*, 24(6), 1–29. <https://doi.org/10.3390/s24061871>
- Sahu, R., & Tripathi, P. (2025). An intelligent forecasting system in Internet of Agriculture Things sensor network. *Ad Hoc Networks*, 169(December 2024), 103752. <https://doi.org/10.1016/j.adhoc.2024.103752>
- Shayea, I., Alhammadi, A., El-Saleh, A. A., Hassan, W. H., Mohamad, H., & Ergen, M. (2022). Time series forecasting model of future spectrum demands for mobile broadband networks in Malaysia, Turkey, and Oman. *Alexandria Engineering Journal*, 61(10), 8051–8067. <https://doi.org/10.1016/j.aej.2022.01.036>
- Zhang, H., Guan, H., Yan, H., Li, W., Yu, Y., Zhou, H., & Zeng, X. (2018). Webshell traffic detection with character-level features based on deep learning. *IEEE Access*, 6, 75268–75277. <https://doi.org/10.1109/ACCESS.2018.2882517>