

# Implementasi LDA untuk Pengelompokan Topik Twitter Bertagar #Mypertamina

Hery Oktafiandi

Teknologi Rekayasa Perangkat Lunak Politeknik Sawunggalih Aji

Email : [heryokta@gmail.com](mailto:heryokta@gmail.com)

## Abstrak

Media sosial twitter banyak digunakan oleh pengguna sebagai media komunikasi dan informasi. Selain sebagai alat komunikasi twitter digunakan untuk mendapatkan data penelitian yang dibutuhkan. Penggunaan tagar twitter menjadi acuan trending berita atau isu yang sedang berkembang di masyarakat. Trending yang sedang hangat dibicarakan saat ini adalah tentang aplikasi Mypertamina. Penelitian ini mengambil data dari twitter dengan tagar #Mypertamina dengan banyak data twitter sebanyak 149 tweet, dari data yang didapat maka akan diklusterkan menggunakan topic modelling metode Latent Dirichlet Allocation (LDA). Kelebihan dari metode LDA adalah dapat mengklusterkan, meringkas, dan menghubungkan data dalam jumlah yang banyak. Penelitian ini menghasilkan 3 kluster data dengan nilai coherence terbesar 0.468

**Kata kunci** Mypertamina, Twitter, LDA.

## Abstract

Twitter social media is widely used by users as a medium of communication and information. Apart from being a communication tool, Twitter is used to obtain the required research data. The use of the twitter hashtag becomes a reference for trending news or issues that are developing in the community. The trend that is currently being discussed is the Mypertamina application. This study takes data from twitter with the hashtag #Mypertamina with a lot of twitter data as many as 149 tweets, from the data obtained it will be clustered using topic modeling with the Latent Dirichlet Allocation (LDA) method. The advantage of the LDA method is that it can cluster, summarize, and link large amounts of data. This study resulted in 3 data clusters with the largest coherence value of 0.4618

**Keywords:** Mypertamina, Twitter, LDA

## 1. Pendahuluan

Layanan twitter yang paling populer sekarang adalah layanan *microblogging* yang digunakan pada media internet (Binsaeed et al., 2020). Ketertarikan pada data twitter terus tumbuh karena banyak data yang dapat diolah (Kearney, 2019). Tagar pada twitter sebagai acuan trending berita atau isu yang berkembang pada masyarakat, disini kami melakukan analisis topik yang sedang trend (Carneiro et al., 2021) berlangsung dari pertengahan bulan juni hingga juli 2022 yaitu #Mypertamina, adanya perkembangan *e-commerce* menghadirkan suatu inovasi pembayaran elektronik (Ibrahim & Karina Moeliono, 2020) yang akan digunakan sebagai alat pembayaran pada pengisian bahan bakar, hal ini banyak pengguna Twitter yang membahas soal aplikasi ini hingga menjadi trending topik seluruh Indonesia.

Penelitian sebelumnya meneliti topik kesehatan di Indonesia menggunakan metode topic modeling

LDA yang menggunakan sumber data dari penelitian khusus dibidang kesehatan Indonesia dan *scraping* data dari jurnal SINTA yang diperoleh dari bulan januari 2020 dan memiliki *scraping* sebanyak 11269 penelitian (Sistem et al., 2021), pada penelitian ini menghasilkan 3 kelompok model. Fazha Rahhid d.k.k (Rashif et al., 2021) melakukan penelitian mengenai cuitan akun bot pada tagar #covid19 menggunakan metode LDA menggunakan data 128 tweet dan mendapatkan hasil 5 topik teratas

Penelitian ini menggunakan Metode LDA (Latent Dirichlet Allocation) untuk mengetahui macam-macam topik yang dibahas terhadap penyebaran informasi di social media Twitter yang membahas aplikasi buatan Pertamina dengan menggunakan tagar #mypertamina.

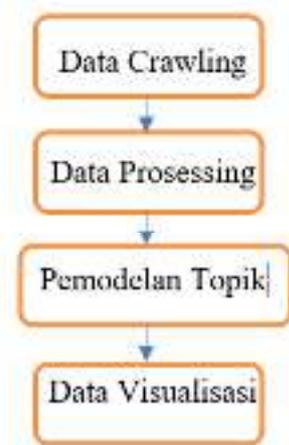
### 1.1. Topic Modeling

Dasar dari topic modeling adalah kluster kata yang berisi kata-kata yang menyusun kluster

tersebut serta memiliki kemungkinan dari beberapa cluster katadengan masing – masing probabilitas. Topic modelling telah mencapai kemajuan yang mengesankan dengan perkembangan cepat model generatif saraf(Yu et al., 2022).

Sejumlah dokumen mempunyai penyebaran probabilitas kluster, tiap kata diambil dari salah satu kluster tersebut.

Dalam sesi ini kami juga menggunakan beberapa teknik pemodelan salah satunya yaitu topik pemodelan, adalah teknik paling kuat untuk text-mining, penemuan data dan menemukan hubungan antar data dan dokumen teks. Para peneliti telah menerbitkan banyak artikel dan jurnal di bidang pemodelan yang mencakup perangkat lunak rekayasa , ilmu politik, bahasam dan ilmu medic(Jelodar et al., 2019).



Gambar 1. Tahapan Metode Penelitian

1.2. Latent Dirichlet Allocation (LDA)

Salah satu metode yang dapat digunakan dalam pemodelan topik yaitu latent dirichlet allocation (LDA). Latent dirichlet allocation (LDA) memiliki keunggulan bisa mengklusterkan data yang jumlahnya besar dibandingkan metode pemodelan topik yang lain serta dapat diimplementasikan untuk mengidentifikasi topik dalam jurnal ilmiah, klasifikasi, dan pengelompokan(Putri et al., 2021).

1.3. Nilai Coherence

Nilai coherence digunakan untuk mengevaluasi model pada topic modelling, nilai koherensi yang tinggi akan menghasilkan model topik yang baik.

2. Pembahasan

Ada beberapa tahap – tahap dalam penelitian ini , yaitu :

1. Data Crawling
2. Data Processing
3. Pemodelan topic
4. Data visualisasi

Berikut penjelasan dari masing – masing tahapan penelitian.

2.1. Data Crawling

Crawling data yang menggunakan HTTP GET dengan kredensiap biasa di hadirkan oleh konsol pengembang Twitter(Sohail et al., 2021), data diambil dari media sosial twitter API(Putri et al., 2021). Crawling data dengan mengumpulkan tweet dengan tagar #mypertamina dengan bahasa Indonesia dijalankan pada bahasa pemrograman Python yang mendukung banyak bahasa manusia(Qi et al., 2020).

Data yang digunakan pada penelitian ini dengan mengambil data pada twitter bertagar #Mypertamina dengan proses crawling. Gambar 2 merupakan contoh dari hasil crawling data tweet tagar#Mypertamina.

ID	id_tweet	id_user	nama	nama_lengkap	nama_lengkap
11	15432109876543210	12345678901234567	Andi	Andi Pratomo	Andi Pratomo
12	15432109876543211	12345678901234568	Budi	Budi Pratomo	Budi Pratomo
13	15432109876543212	12345678901234569	Cici	Cici Pratomo	Cici Pratomo
14	15432109876543213	12345678901234570	Dani	Dani Pratomo	Dani Pratomo

Gambar 2 Kumpulan Data Tweet





Gambar 6. Pemodelan Topik Modeling

Hasil dari pemodelan dapat dilihat pada tabel 1 berupa 10 kata kunci teratas pada topik – topik yang dibentuk.

Tabel 1. Hasil Topik Modeling

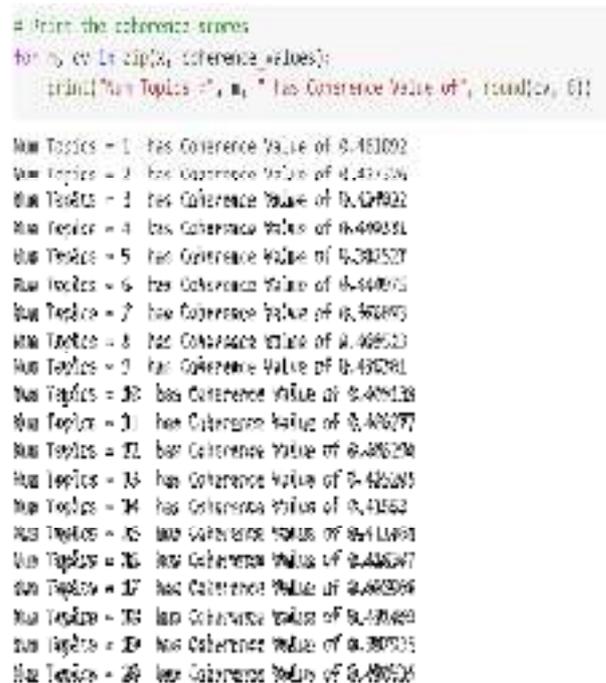
Topik	Probabilitas* Kata
0	0.053*"pertalite"+0.033*"kendaraan"+0.032 *"bbmbersubsidi"+0.024*"spbu" +0.025"pakai" +0.025"mobil" 0.02*"sudah"+0.019*"dan" +0.019*"untuk"
1	+0.52mypertamina_call135 +0.023dan+0.022call135 +0.022ada +0.019mmc_milenial 0.018my_pertamina +0.017my +0.017kamu+0.017yg +0.017lebihbaikpertamax
2	0.027bisa+0.026subsidi +0.026mypertamina_call135 +0.026penggunaan +0.023pertalite+0.022jadi +0.021daftar +0.021bikin+0.020data +0.019punya

Dari hasil topik modeling yang didapat maka dilakukan analisa pada hasil topic yang terbentuk. Tabel 2 merupakan analisa hasil topic modeling yang telah dianalisa.

Tabel 2. Hasil Analisa Topik

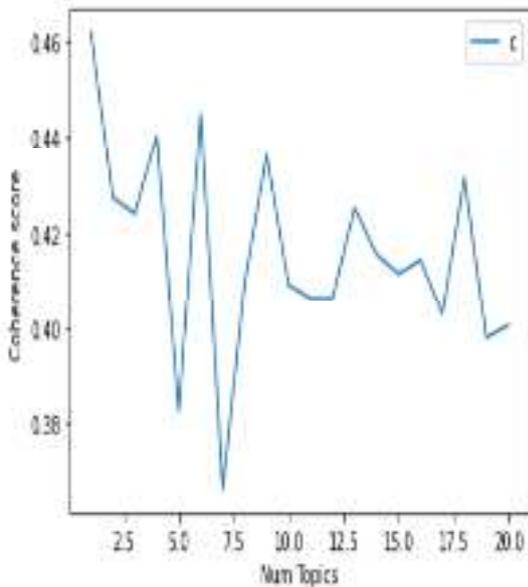
Topik	Hasil Analisa Topik
0	Kendaraan mobil memakai bbm bersubsidi
1	My Pertamina_call135 lebih baik pertamax My Pertamina punya data daftar pengguna bbm
2	bersubsidi pertalite

Tahapan selanjutnya adalah perhitungan nilai coherence, gambar 5 merupakan hasil dari nilai coherence yang didapat



Gambar 7 Nilai Coherence

Semakin besar nilai coherence maka interpretasi topic modeling yang dihasilkan semakin baik. Nilai coherence yang terbaik pada penelitian ini bernilai 0.418 terdapat pada topik 1. Nilai coherence juga bisa dilihat pada gambar 6 yang merupakan gambar grafik nilai coherence



Gambar 8. Grafik Nilai Coherence

2.4. Data Visualisasi

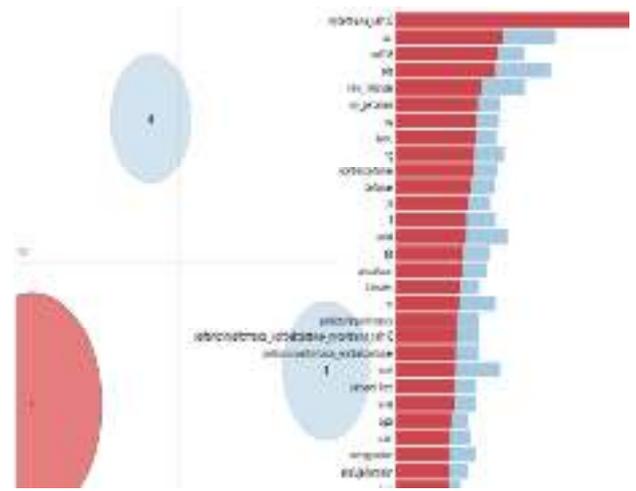
Visualisasi penerapan LDA menggunakan grafik dan *bar-chart* dengan memanfaatkan *tool PyLDAvis* pada *python* (Sezer & Ozbayoglu, 2020). *PyLDAvis* digunakan untuk menterjemahkan kluster yang terbentuk sesuai dengan data.

Pemodelan LDA telah dibangun selanjutnya visualisasi hasil pemodelan. Visualisasi data menggunakan modul *PyDavis* pada *python*. Visualisasi membantu menterjemahkan topic sesuai dengan kumpulan data. Pada gambar visualisasi terlihat 2 gambar, sebelah kiri menunjukkan topic secara keseluruhan dan dapat terlihat hubungan antar topik. Bagian sebelah kanan menunjukkan distribusi frekuensi kata pada setiap topik.

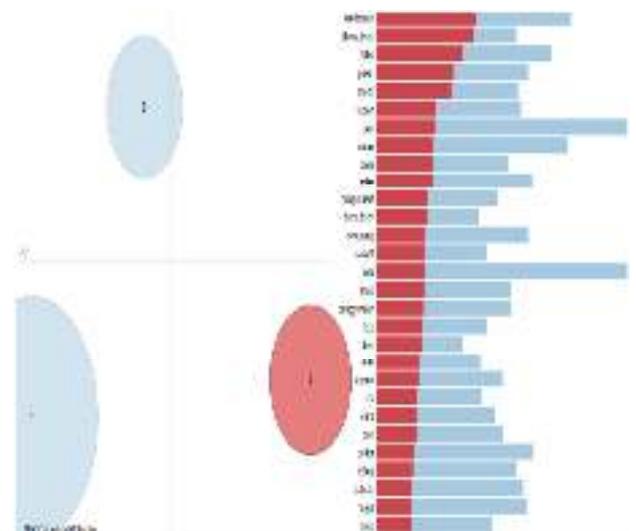
Pada penelitian ini terdapat 3 model topik yang terbangun. Topik 1 terlihat pada gambar 7 terdapat 30 *terminologi* kata yang terdapat pada topic. Pada topic 1 membahas tentang *my Pertamina\_call135*, *my Pertamina*, *call135*, lebih baik *Pertamax*, *Pertamax*, pendaftaran, transaksi, ini, ribet, dan transaksi *bbm*.

Topik 2 dapat dilihat pada gambar 8 membahas tentang kendaraan, *bbm subsidi*, *spbu*, *pakai*, mobil, sudah, masyarakat, *bersubsidi*, rakyat.

Topik 3 terlihat pada gambar 9, diantaranya membahas tentang bisa, subsidi, *my Pertamina\_call135*, penggunaan, *pertalite*, cara, bikin, daftar.



Gambar 9. Topik 1



Gambar 10 Topik 2



Gambar 11 Topik 3

### 3. Kesimpulan

Metode pengklasteran LDA pada twitter bertagat #mypertamina mengelompokkan data twitter menjadi 3 buah topic. Dari sejumlah topic yang dipilih diperoleh nilai *coherence* tertinggi sebesar 0.4618. Melihat hasil topic modeling yang terbentuk dapat disimpulkan tweet dengan tagar#Mypertamina membahas tentang Mypertamina\_call135, pertamax, bbm bersubsidi dan pertalite. Kekurangan pada penelitian ini belum adanya perbandingan perhitungan manual, penelitian ini hanya menggunakan modul yang ada pada python.

### Daftar Pustaka

- Ahmadi, S. (2020). A Tokenization System for the Kurdish Language. *Proceedings of the 7th Workshop on NLP for Similar Languages, Varieties and Dialects*, 114–127.
- Binsaeed, K., Stringhini, G., & Youssef, A. E. (2020). Detecting Spam in Twitter Microblogging Services: A Novel Machine Learning Approach based on Domain Popularity. In *IJACSA International Journal of Advanced Computer Science and Applications* (Vol. 11, Issue 11).
- Carneiro, A., Matos, M. J., Uriarte, E., & Santana, L. (2021). Trending topics on coumarin and its derivatives in 2020. In *Molecules* (Vol. 26, Issue 2). MDPI AG. <https://doi.org/10.3390/molecules26020501>
- Hasan, M., Rahman, A., Karim, M. R., Khan, M. S. I., & Islam, M. J. (2021). Normalized approach to find optimal number of topics in latent dirichlet allocation (lda). *Advances in Intelligent Systems and Computing*, 1309, 341–354. [https://doi.org/10.1007/978-981-33-4673-4\\_27](https://doi.org/10.1007/978-981-33-4673-4_27)
- Ibrahim, R. M., & Karina Moeliono, N. N. (2020). Persepsi manfaat, kepercayaan, efikasi diri, kemudahan penggunaan, keamanan terhadap persepsi konsumen pada my pertamina (Studi pada penggunaan my pertamina kota Bandung. *Jurnal Ilmiah Mahasiswa Ekonomi Manajemen Accredited SINTA*, 4(2), 396–413.
- Impraimakis, M., & Smyth, A. W. (2022). Input–parameter–state estimation of limited information wind-excited systems using a sequential Kalman filter. *Structural Control and Health Monitoring*, 29(4). <https://doi.org/10.1002/stc.2919>
- Jelodar, H., Wang, Y., Yuan, C., Feng, X., Jiang, X., Li, Y., & Zhao, L. (2019). Latent Dirichlet allocation (LDA) and topic modeling: models, applications, a survey. In *Multimedia Tools and Applications* (Vol. 78, Issue 11). <https://doi.org/10.1007/s11042-018-6894-4>
- Kearney, M. (2019). rtweet: Collecting and analyzing Twitter data. *Journal of Open Source Software*, 4(42), 1829. <https://doi.org/10.21105/joss.01829>
- Purwitasari, D., Aida Muflichah, Novrindah Alvi Hasanah, & Agus Zainal Arifin. (2021). Pemodelan Topik dengan LDA untuk Temu Kembali Informasi dalam Rekomendasi Tugas Akhir. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(3), 421–428. <https://doi.org/10.29207/resti.v5i3.3049>
- Putri, S. A., Kusuma, P. D., & Setianingsih, C. (2021). Clustering Topik Pada Data Sentimen BPJS Kesehatan Menggunakan Metode Laten Dirichlet Allocation. *E-Proceeding of Engineering*, 8(5), 6097–6105.
- Qi, P., Zhang, Y., Zhang, Y., Bolton, J., & Manning, C. D. (2020). *Stanza: A Python Natural Language Processing Toolkit for Many Human Languages*. 101–108. <https://doi.org/10.18653/v1/2020.acl-demos.14>
- Rashif, F., Ihza Perwira Nirvana, G., Alif Noor, M., & Aini Rakhmawati, N. (2021). Implementasi LDA untuk Pengelompokan Topik Cuitan Akun Bot Twitter bertagat #Covid-19 LDA Implementation for Topic of Bot's Tweets with #Covid-19 Hashtag. *Cogito Smart Journal* |, 7(1), 170–181.
- Sezer, O. B., & Ozbayoglu, A. M. (2020). Financial trading model with stock bar chart image time series with deep convolutional neural networks. *Intelligent Automation and Soft Computing*, 26(2), 323–334. <https://doi.org/10.31209/2018.100000065>
- Sistem, R., Sahria, Y., & Fudholi, D. H. (2021). JURNAL RESTI Analisis Topik Penelitian Kesehatan di Indonesia Menggunakan Metode. *Jurnal Rekayasa Sistem Dan Teknologi Informasi (RESTI)*, 1(10), 336–344.
- Sohail, S. S., Khan, M. M., Arsalan, M., Khan, A., Siddiqui, J., Hasan, S. H., & Alam, M. A. (2021). *Crawling Twitter data through API: A technical/legal perspective*.
- Sun, W., Cai, Z., Li, Y., Liu, F., Fang, S., & Wang, G. (2018). Data processing and text mining technologies on electronic medical records: A

review. In *Journal of Healthcare Engineering* (Vol. 2018). Hindawi Limited.  
<https://doi.org/10.1155/2018/4302425>

Yu, P., Xie, S., Ma, X., Jia, B., Pang, B., Gao, R., Zhu, Y., Zhu, S.-C., & Wu, Y. N. (2022). *Latent Diffusion Energy-Based Model for Interpretable Text Modeling*. 2020.