

## Analisis Tren Topik dalam Ulasan Negatif Aplikasi M-Banking Menggunakan Latent Dirichlet Allocation

Kartikadyota Kusumaningtyas<sup>1</sup>, Irmma Dwijayanti<sup>2</sup>, Alfirna Rizqi Lahitani<sup>3</sup>, Muhammad Habibi<sup>4</sup>

<sup>1,4</sup>Informatika, Fakultas Teknik dan Teknologi Informasi, Universitas Jenderal Achmad Yani Yogyakarta

<sup>2</sup>Informatika, Fakultas Teknik dan Teknologi Informasi, Universitas Jenderal Achmad Yani Yogyakarta

<sup>3</sup>Teknologi Informasi, Fakultas Teknik dan Teknologi Informasi, Universitas Jenderal Achmad Yani Yogyakarta

<sup>1</sup>kartikadyota@gmail.com\*, <sup>2</sup>irmmadwijayanti@gmail.com, <sup>3</sup>alfirnalahitani@gmail.com, <sup>4</sup>muhammadhabibi17@gmail.com

### Abstract

Mobile banking is increasingly in demand, driven by the National Non-Cash Movement and banking innovation. Quick response to negative reviews is important to maintain user trust, but Google Play Store has not provided a feature to analyze review topic trends. This study aims to analyze topic trends in negative reviews of M-banking applications using Support Vector Machine (SVM) algorithm for sentiment analysis and Latent Dirichlet Allocation (LDA) algorithm for topic modeling. The SVM model showed high performance with accuracy 93%, precision 95%, recall 95%, and F1-score 95%. LDA determined the best number of topics with the highest coherence scores: BRImo (0.459, 11 topics), BCA mobile (0.450, 3 topics), and Livin' by Mandiri (0.331, 10 topics). Topic visualization using distance map shows overlapping or similar themes between topics in the BRImo and Livin' by Mandiri applications, so they can be combined into the same topic category. After merging similar themes, the BRImo, BCA mobile, and Livin' by Mandiri applications have 7, 3, and 4 topic categories. The analysis results show that negative reviews of BRImo predominantly discuss costs and service speed, BCA mobile focuses on features and ease of use, while Livin' by Mandiri focuses on transfer features and transaction hours.

Keywords: LDA, SVM, topic modeling, mobile banking, critical reviews.

### Abstrak

Mobile banking semakin diminati, didorong oleh Gerakan Nasional Non-Tunai dan inovasi perbankan. Respons cepat terhadap ulasan negatif penting untuk menjaga kepercayaan pengguna, tetapi Google Play Store belum menyediakan fitur analisis tren topik ulasan. Penelitian ini bertujuan untuk menganalisis tren topik dalam ulasan negatif aplikasi M-banking dengan memanfaatkan algoritma Support Vector Machine (SVM) untuk analisis sentimen dan algoritma Latent Dirichlet Allocation (LDA) untuk pemodelan topik. Model SVM menunjukkan performa tinggi dengan nilai *accuracy* 93%, *precision* 95%, *recall* 95%, dan *F1-score* 95%. LDA menentukan jumlah topik terbaik dengan *coherence score* tertinggi: BRImo (0,459, 11 topik), BCA mobile (0,450, 3 topik), dan Livin' by Mandiri (0,331, 10 topik). Visualisasi topik menggunakan *distance map* menunjukkan adanya *overlap* atau kesamaan tema antar topik pada aplikasi BRImo dan Livin' by Mandiri, sehingga dapat digabungkan menjadi kategori topik yang sama. Setelah penggabungan tema yang serupa, aplikasi BRImo, BCA mobile, dan Livin' by Mandiri memiliki 7, 3, dan 4 kategori topik. Hasil analisis menunjukkan ulasan negatif BRImo dominan membahas biaya dan kecepatan layanan, BCA mobile fokus pada fitur dan kemudahan penggunaan, sedangkan Livin' by Mandiri pada fitur transfer dan jam transaksi.

Kata kunci: SVM, LDA, pemodelan topik, mobile banking, ulasan negatif

©This work is licensed under a Creative Commons Attribution -ShareAlike 4.0 International License

### 1. Pendahuluan

Mobile banking atau M-banking menjadi semakin populer seiring dengan meluasnya penggunaan ponsel pintar. Dengan kemudahan dalam mengelola keuangan dan melakukan transaksi saat bepergian, aplikasi M-banking telah mendapatkan daya tarik yang signifikan [1], [2]. Hal ini juga dibuktikan dengan adanya lonjakan pertumbuhan transaksi QRIS bulan Agustus 2024 mencapai 217,33% secara tahunan dengan jumlah pengguna mencapai 52,55 juta [3], [4]. Pertumbuhan ini didorong oleh beberapa faktor, seperti kebijakan pemerintah melalui Gerakan Nasional Non-Tunai (GNNT) [5] dan inovasi dari bank [6], [7].

Menurut survei yang dilakukan oleh CNBC Indonesia Research, tiga aplikasi m-banking dengan jumlah pengguna terbanyak di Indonesia adalah BRI Mobile, BCA mobile, dan Livin' by Mandiri [8]. Melalui Google Play Store, pengguna aplikasi dapat berbagi pengalaman mereka dengan memberikan *rating* dan ulasan [9]. Ulasan positif umumnya mencerminkan kepuasan pengguna, sementara ulasan negatif mengungkapkan ketidakpuasan yang seringkali berkaitan dengan berbagai masalah dalam pengalaman pengguna. Respon cepat dan tepat dari penyedia layanan terhadap ulasan negatif berpotensi meningkatkan kepuasan pelanggan dan membangun kepercayaan dalam layanan tersebut [10], [11]. Namun,

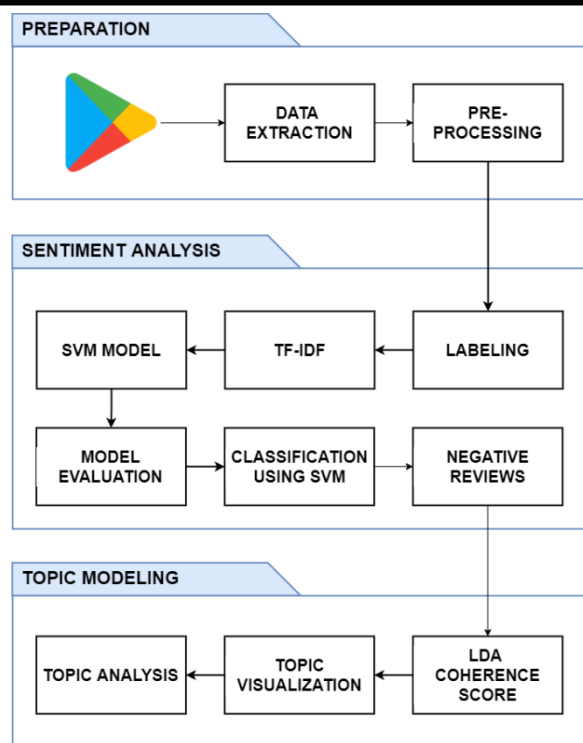
tanpa pemahaman yang jelas tentang topik-topik utama dalam ulasan negatif, penyedia layanan akan menghadapi tantangan dalam memberikan tanggapan yang efektif. Hal ini juga didukung dengan belum adanya fitur pada Google Play Store untuk menampilkan tren topik dalam ulasan negatif, sehingga analisis manual menjadi tidak efisien dan kurang sistematis.

Penelitian ini bertujuan untuk mengisi celah tersebut dengan menggunakan metode *Latent Dirichlet Allocation* (LDA) untuk memodelkan topik dalam ulasan negatif pada aplikasi *m-banking* di Google Play Store. LDA adalah teknik *unsupervised* yang secara otomatis mengidentifikasi topik berdasarkan pola kemunculan kata dalam dokumen [12]. Penelitian ini tidak hanya diharapkan memberikan informasi tentang tren topik dalam ulasan negatif pengguna, tetapi juga memberikan wawasan berharga bagi penyedia layanan untuk meningkatkan kualitas aplikasi, memperkuat ketahanan sistem keuangan digital, dan meminimalkan kerentanan terhadap ancaman siber. Dalam konteks ketahanan nasional, ulasan negatif yang menyoroti masalah seperti keamanan, privasi, atau kualitas layanan dapat mengancam kepercayaan masyarakat terhadap sistem keuangan digital yang semestinya dapat diandalkan [13].

Meskipun penelitian sebelumnya telah membahas analisis sentimen pada ulasan aplikasi *m-banking* [9], [14] dan beberapa penelitian terkait pemodelan topik menggunakan LDA telah dilakukan, seperti pada konten GERMAS [15], UU ITE [16], data Twitter terkait bencana banjir di Jakarta [17], pengalaman konsumen terhadap produk skincare [18], serta ulasan pengguna pada aplikasi PeduliLindungi [19] dan Shopee [20], namun belum ada penelitian yang secara spesifik berfokus pada analisis topik tersembunyi dalam ulasan negatif pengguna aplikasi *m-banking* di Google Play Store.

## 2. Metode Penelitian

Terdapat tiga tahapan utama untuk mencapai tujuan penelitian yang telah ditetapkan, yaitu Persiapan (*Preparation*), Analisis Sentimen (*Sentiment Analysis*), dan Pemodelan Topik (*Topic Modeling*). Tahap Persiapan terdiri dari proses ekstraksi data dari Google Play Store dan *pre-processing*. Tahap Analisis Sentimen terdiri dari pelabelan, ekstraksi fitur menggunakan TF-IDF, membangun model SVM, evaluasi model menggunakan *confusion matrix*, klasifikasi data ulasan menggunakan model SVM, dan mengambil data ulasan negatif untuk diproses pada Tahap Pemodelan Topik. Tahap Pemodelan Topik terdiri dari perhitungan *coherence score*, visualisasi topik, dan analisis topik. Gambar 1 menunjukkan tahapan penelitian yang dilakukan.



Gambar 1. Tahapan Penelitian

### 2.1. Preparation

#### 2.1.1. Data Extraction

Tahap persiapan dimulai dengan proses pengumpulan data. Pengumpulan data dilakukan dengan cara mengekstrak data ulasan aplikasi BRImo, BCA mobile, dan Livin' by Mandiri pada website Google Play Store. Jumlah data yang diperoleh ditunjukkan Tabel 1.

Tabel 1. Hasil Pengumpulan Data

Aplikasi	Jumlah Data
BRImo	2587
BCA Mobile	1990
Livin' by Mandiri	1791

#### 2.1.2. Pre-processing

Langkah berikutnya adalah membersihkan dan mempersiapkan data untuk analisis. Tahapan *pre-processing*, meliputi:

- Case folding*, mengubah huruf kapital (*uppercase*) menjadi huruf kecil (*lowercase*).
- Filtering*, digunakan untuk membersihkan teks dari karakter khusus dan angka.
- Tokenizing*, memecah kalimat menjadi kata (token)
- Stopwords removal*, menghapus kata-kata umum yang tidak mengandung informasi penting.
- Stemming*, mengubah kata menjadi bentuk dasar.

### 2.2. Sentiment Analysis

Analisis sentimen adalah proses menggunakan teknik pemrosesan bahasa alami, analisis teks, atau pembelajaran mesin untuk mengidentifikasi, perasaan atau sikap seseorang terhadap suatu topik, produk, layanan, peristiwa atau isu tertentu [21]. Tujuan utama dari analisis sentimen adalah memahami apakah

sentimen yang terkandung dalam teks bersifat positif, negatif, atau netral. Pada penelitian ini, analisis sentimen digunakan untuk mengidentifikasi ulasan positif dan ulasan negatif yang terdapat pada aplikasi *m-banking*.

### 2.2.1 Labeling

*Labeling* adalah proses memberikan tanda atau kategori pada data teks berdasarkan jenis sentimennya. Tujuan pelabelan adalah menyediakan data yang sudah diklasifikasikan agar dapat digunakan untuk melatih model SVM. Pada penelitian ini pelabelan positif dan negatif dilakukan secara manual oleh manusia. Tabel 2 menunjukkan contoh pelabelan yang dihasilkan.

Tabel 2. Contoh Pelabelan Data

Ulasan	Kelas
Aplikasinya sangat membantu, transfer cepat dan mudah digunakan	Positif
Aplikasi sering crash saat login, sangat mengecewakan	Negatif

### 2.2.2. TF-IDF

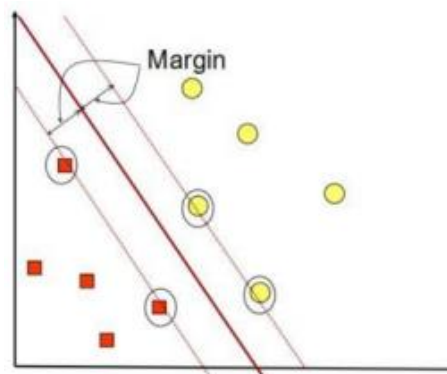
*Term Frequency-Inverse Document Frequency* (TF-IDF) merupakan metode untuk menilai kepentingan suatu kata dalam suatu dokumen relatif terhadap sekumpulan dokumen (*corpus*). Proses ini akan mengubah setiap kata berbentuk token yang sudah melalui tahap *pre-processing* menjadi vektor yang akan merepresentasikan kata yang ada. *Term Frequency* (TF) mengukur seberapa sering kata muncul dalam sebuah dokumen. *Inverse Document Frequency* (IDF) mengukur seberapa unik atau jarang kata tersebut muncul di seluruh dokumen dalam korpus. Adapun persamaan dalam penghitungan TF-IDF ditunjukkan pada persamaan 1.

$$TF - IDF = f_{t,d} \times \log \left( \frac{N}{n_t} \right) \quad (1)$$

dengan  $f_{t,d}$  adalah jumlah kemunculan kata  $t$  dalam dokumen  $d$ ,  $N$  adalah jumlah total dokumen dalam *corpus*, dan  $n_t$  adalah jumlah dokumen yang mengandung kata  $t$ .

### 2.2.3. Support Vector Machine

*Support Vector Machine* (SVM) adalah algoritma pembelajaran mesin dengan tipe *supervised* berbasis vektor[22]. SVM bekerja dengan mencari *hyperplane* (garis atau bidang pemisah) terbaik yang memisahkan data ke dalam dua kategori berbeda di ruang fitur[23]. *Hyperplane* berada di antara dua kelas dengan jarak  $d$  pada titik terdekat setiap kelas. Jarak  $d$  ini disebut dengan margin dan titik yang berada pada *margin* ini disebut sebagai *support vector*. Representasi SVM ditunjukkan Gambar 2.



Gambar 2. Representasi SVM [22]

Dataset dibagi menjadi dua bagian, yaitu data latih (*training data*) dan data uji (*testing data*)[24]. Data latih digunakan untuk melatih model, sedangkan data uji digunakan untuk mengevaluasi kinerja model. Dataset ulasan aplikasi BCA Mobile yang terdiri dari 1990 ulasan dibagi menjadi 70% (1393 ulasan) untuk *training data* dan 30% (597 ulasan) untuk *testing data*.

Pengujian model dilakukan menggunakan data uji untuk melihat seberapa baik model memprediksi sentimen. Pada tahap ini, SVM akan menggunakan *hyperplane* yang telah ditemukan selama masa latih (*training*) untuk memprediksi kelas sentimen dari data baru.

### 2.2.4. Model Evaluation

*Confusion matrix* merupakan salah satu metode yang digunakan untuk mengevaluasi performa model. Pada tahapan ini, *confusion matrix* digunakan untuk mengetahui performansi dari setiap kernel algoritma SVM dengan hasil evaluasi berupa nilai *accuracy*, *precision*, *recall*, dan *F1-score*. *Accuracy* menunjukkan proporsi prediksi yang benar terhadap seluruh data yang diuji (persamaan 2). *Precision* menunjukkan proporsi prediksi *True Positive* dari seluruh prediksi positif (persamaan 3). *Recall* menunjukkan proporsi data positif yang benar-benar terprediksi sebagai positif (persamaan 4). *F1-Score* merupakan rata-rata harmonis dari *precision* dan *recall* (persamaan 5).

$$Accuracy = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

$$Precision = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (4)$$


$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \times 100\% \quad (5)$$

dengan TP adalah *True Positive*, TN adalah *True Negative*, FP adalah *False Positive*, dan FN adalah *False Negative* [25].

### 2.3. Latent Dirichlet Allocation

*Latent Dirichlet Allocation* (LDA) adalah salah satu metode populer dalam pemodelan topik yang digunakan untuk menemukan struktur tersembunyi dalam kumpulan data teks. LDA mengelompokkan

dokumen ke dalam beberapa topik berdasarkan kemunculan kata-kata tertentu dalam setiap dokumen. Metode ini merupakan pendekatan berbasis *generative probabilistic model* yang menganggap bahwa setiap dokumen merupakan campuran dari beberapa topik, dan setiap topik adalah distribusi dari kata-kata [26]. Oleh karena itu, algoritma ini sangat cocok untuk data teks. Representasi LDA dapat dilihat pada Gambar 3.



Gambar 3. Representasi LDA [26]

Parameter utama LDA mencakup  $\alpha$  dan  $\beta$ , yang merupakan parameter Dirichlet.  $\alpha$  menentukan keragaman topik dalam dokumen. Nilai  $\alpha$  yang tinggi menunjukkan bahwa dokumen cenderung memiliki campuran banyak topik, sedangkan nilai yang rendah membuat dokumen hanya mencakup beberapa topik dominan. Sebaliknya,  $\beta$  mengatur keragaman kata dalam topik. Nilai  $\beta$  yang tinggi menunjukkan bahwa topik berisi beragam kata, sementara nilai rendah menunjukkan adanya beberapa kata dominan dalam tiap topik.

Variabel utama dalam LDA adalah  $\theta$ ,  $z$ , dan  $w$ .  $\theta$  adalah distribusi topik dalam dokumen, yang ditentukan oleh parameter  $\alpha$ . Variabel  $z$  menunjukkan topik yang dipilih untuk setiap kata dalam dokumen, sedangkan  $w$  adalah kata sebenarnya dalam dokumen, yang diambil berdasarkan distribusi kata pada topik yang dipilih. Seluruh proses ini diulang untuk setiap dokumen, menghasilkan representasi topik yang berbeda untuk setiap kata dan dokumen.

Sebelum melakukan pemodelan topik dengan LDA, perlu diputuskan jumlah topik optimalnya. *Coherence Score* adalah salah satu metrik evaluasi yang mengukur seberapa koheren (logis dan terstruktur) topik-topik yang dihasilkan. *Coherence Score* membantu memilih jumlah topik terbaik yang memberikan hasil pemodelan topik paling koheren.

### 3. Hasil dan Pembahasan

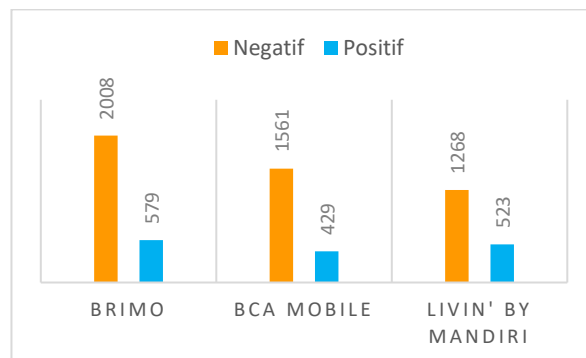
#### 3.1. Analisis Sentimen

Analisis sentimen dilakukan menggunakan algoritma SVM yang telah melalui proses pelatihan dengan hasil evaluasi seperti ditunjukkan Tabel 3.

Tabel 3. Hasil *Confusion Matrix*

Aspek	Nilai
Accuracy	93%
Precision	95%
Recall	95%
F1-score	95%

Berdasarkan hasil evaluasi yang ditunjukkan pada Tabel 3, dapat diketahui bahwa model SVM menunjukkan performa yang baik. Selanjutnya model tersebut digunakan untuk mengklasifikasikan seluruh data ulasan pada masing-masing aplikasi *m-banking*. Distribusi ulasan negatif dan ulasan positif pada masing-masing aplikasi *m-banking* ditunjukkan pada Gambar 4.



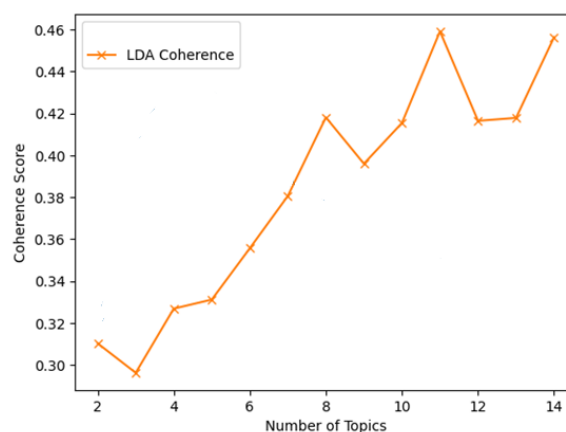
Gambar 4. Distribusi Ulasan Negatif dan Ulasan Positif

Berdasarkan hasil analisis sentimen (ditunjukkan Gambar 4), maka dapat diketahui bahwa pada tiap aplikasi *m-banking* jumlah ulasan negatif mendominasi. Proses selanjutnya adalah mengambil data ulasan negatif untuk proses pemodelan topik.

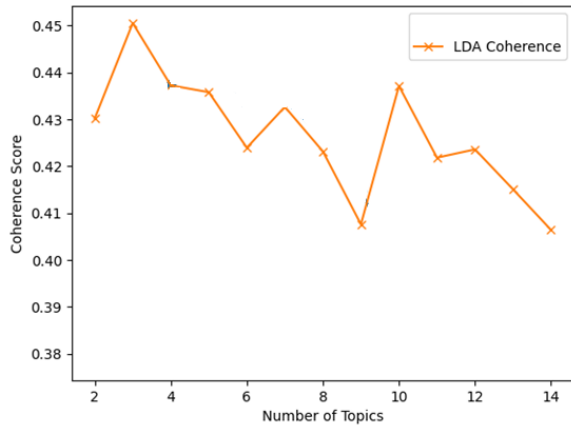
#### 3.2. Coherence Score

Pemodelan topik diawali dengan menentukan jumlah  $k$ -topik terbaik untuk pembuatan model LDA. Pemilihan jumlah topik yang optimal sangat penting karena jumlah topik yang terlalu sedikit bisa membuat model tidak dapat menangkap variasi tema yang ada di dalam kumpulan dokumen, sementara jumlah topik yang terlalu banyak bisa membuat hasil analisis menjadi terlalu tersebar dan sulit diinterpretasikan.

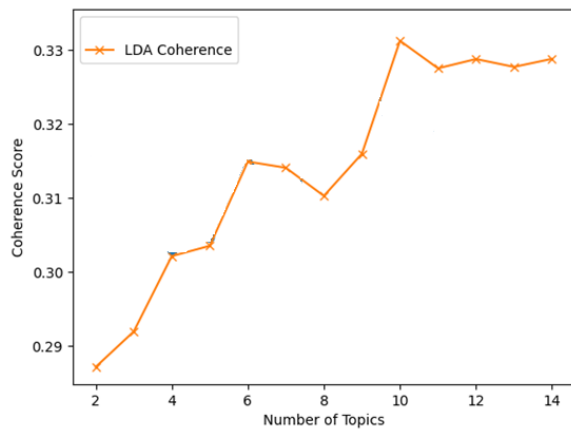
Metode populer yang digunakan untuk menentukan jumlah topik adalah menggunakan *coherence score*. *Coherence score* mengukur tingkat keterkaitan antara kata-kata dalam sebuah topik. Semakin tinggi *coherence score*, semakin baik kualitas topik. Gambar 5-7 menunjukkan *coherence score* pada aplikasi BRImo, BCA mobile, dan Livin' by Mandiri.



Gambar 5. *Coherence Score* BRImo



Gambar 6. Coherence Score BCA Mobile



Gambar 7. Coherence Score Livin' by Mandiri

Dalam percobaan ini, kami mencoba menghasilkan 1 hingga 15 *k*-topik. Jumlah topik terbaik dapat dilihat berdasarkan *coherence score* tertinggi. Tabel 4 merangkum *coherence score* tertinggi dan jumlah topik untuk masing-masing aplikasi *m-banking*.


Tabel 4. Jumlah *k*-Topik Terbaik

Aplikasi	Coherence Score	Jumlah Topik ( <i>k</i> )
BRImo	0,459	11
BCA Mobile	0,450	3
Livin' by Mandiri	0,331	10


Dengan demikian, dapat diketahui bahwa jumlah topik terbaik pada aplikasi BRImo, BCA mobile, dan Livin' by Mandiri adalah 11, 3, 10.

### 3.3. Topic Visualization


Visualisasi topik membantu untuk memahami hubungan antar topik, kata-kata utama dalam setiap topik, dan distribusi topik dalam dokumen. *Distance map* merupakan salah satu cara visualisasi topik yang memberikan wawasan tentang bagaimana topik saling berhubungan berdasarkan istilah/kata yang dimiliki bersama. Gambar 8-10 menunjukkan hasil *distance map* dari 11, 3, 14 topik yang dihasilkan oleh algoritma LDA pada masing-masing aplikasi *m-banking*.



Gambar 8. Distance Map Antar Topik BRImo



Gambar 9. Distance Map Antar Topik BCA Mobile



Gambar 10. Distance Map Antar Topik Livin' by Mandiri

Berdasarkan Gambar 8-10, dapat diketahui bahwa ada beberapa topik yang beririsan dengan topik lainnya dan beberapa topik yang saling lepas. Topik yang beririsan menunjukkan adanya *overlap* atau kesamaan tema, yang berarti beberapa topik memiliki kata-kata kunci yang serupa. Hal ini menunjukkan bahwa beberapa tema dalam dataset berbagi konten yang relevan dan dapat digabungkan menjadi kategori topik yang sama.

### 3.4. Topic Analysis

Berdasarkan hasil *distance map* pada Gambar 8, dapat diidentifikasi keterkaitan antar topik dan menghasilkan pengelompokan topik. Pada aplikasi BRImo, terdapat 5 kelompok topik saling beririsan dan 6 kelompok topik saling lepas, sehingga dapat dibentuk 7 kategori topik (ditunjukkan pada Tabel 5). Topik dengan Kategori A1 dengan ulasan terbanyak membahas terkait biaya dan kecepatan layanan aplikasi.

Tabel 5. Identifikasi Topik Berdasarkan *Distance Map* pada Aplikasi BRImo

Kategori Topik	Topik yang Berhubungan	Deskripsi	Jumlah Ulasan
Kategori A1	1, 2, 3, 4, 5	Biaya dan kecepatan layanan aplikasi	827
Kategori A2	6	Keamanan transaksi	35
Kategori A3	7	Kemudahan transaksi	66
Kategori A4	8	Saldo transaksi	157
Kategori A5	9	Fitur nasabah	12
Kategori A6	10	Login BRImo	400
Kategori A7	11	Perbaikan menu aplikasi BRImo	511

Topik kategori A1 mencakup ulasan tentang biaya layanan dan kecepatan performa aplikasi BRImo, yang menjadi perhatian utama dengan jumlah ulasan terbanyak, yaitu 827 ulasan. Ulasan dalam kategori A2 menyoroti masalah terkait keamanan saat melakukan transaksi di aplikasi BRImo. Jumlah ulasan dalam kategori ini adalah 35. Topik pada kategori A3 berkaitan dengan kemudahan pengguna dalam melakukan transaksi melalui aplikasi, dengan jumlah ulasan sebanyak 66. Kategori A4 berfokus pada ulasan yang menyinggung masalah saldo dalam transaksi, misalnya keterlambatan atau ketidaksesuaian saldo. Jumlah ulasan yang termasuk dalam kategori ini adalah 157. Topik kategori A5 mencakup ulasan mengenai fitur-fitur yang ditawarkan kepada nasabah, dengan total ulasan sebanyak 12. Kategori A6 terkait masalah login atau akses masuk ke aplikasi BRImo, yang merupakan salah satu masalah yang sering dikeluhkan dengan jumlah ulasan sebanyak 400. Ulasan pada kategori A7 mengangkat kebutuhan akan perbaikan atau peningkatan pada menu aplikasi BRImo agar lebih *user-friendly*. Kategori ini memiliki 511 ulasan.

Berdasarkan hasil *distance map* aplikasi BCA mobile pada Gambar 9, dapat diketahui bahwa ketiga topik yang terbentuk tidak saling beririsan, sehingga kelompok topik yang bisa dibentuk adalah 3 kategori (ditunjukkan pada Tabel 6).

Tabel 6. Identifikasi Topik Berdasarkan *Distance Map* pada Aplikasi BCA mobile

Kategori Topik	Topik yang Berhubungan	Deskripsi	Jumlah Ulasan
Kategori B1	1	Interaksi pengguna	568
Kategori B2	2	Kemudahan proses login	405
Kategori B3	3	Fitur dan kemudahan penggunaan aplikasi	582

Dalam kategori B1 dengan jumlah ulasan sebanyak 568 menunjukkan bahwa interaksi pengguna dengan aplikasi menjadi fokus topik dalam ulasan tersebut. Topik pada kategori B2 membahas tentang kemudahan proses login, dengan jumlah 405 ulasan. Sementara itu, kategori B3 membahas topik fitur dan kemudahan penggunaan aplikasi dengan ulasan terbanyak sejumlah 582 ulasan.

Berdasarkan hasil *distance map* pada aplikasi Livin' by Mandiri (Gambar 10) diketahui bahwa 7 topik saling beririsan dan 3 topik saling lepas, sehingga kelompok

topik yang bisa dibentuk adalah 4 kategori (ditunjukkan pada Tabel 7). Topik dengan Kategori C1 dimana dengan ulasan terbanyak membahas terkait fitur transfer dan jam transaksi.

Tabel 7. Identifikasi Topik Berdasarkan *Distance Map* pada Aplikasi Livin' by Mandiri

Kategori Topik	Topik yang Berhubungan	Deskripsi	Jumlah Ulasan
Kategori C1	1, 2, 3, 4, 5, 6, 9	Fitur transfer dan jam transaksi	955
Kategori C2	7	Update aplikasi	91
Kategori C3	8	Kemudahan penggunaan aplikasi	107
Kategori C4	10	Fitur top up saldo	115

Pada kategori C1, topik yang dibahas berhubungan dengan fitur transfer dan jam transaksi, dengan jumlah ulasan terbanyak yaitu 955 ulasan. Topik pada kategori C2 membahas tentang update aplikasi dengan 91 ulasan. Kategori C3 berfokus pada topik kemudahan penggunaan aplikasi, dengan 107 ulasan, menandakan bahwa pengguna memperhatikan aspek kemudahan dalam mengakses dan menggunakan aplikasi tersebut. Topik pada kategori C4 terkait dengan fitur top up saldo dengan 115 ulasan.

#### 4. Kesimpulan

Dari penelitian ini dapat disimpulkan bahwa analisis tren topik pada ulasan negatif aplikasi *mobile banking* menggunakan metode LDA berhasil diterapkan. Ulasan negatif didapatkan dari hasil analisis sentimen menggunakan algoritma SVM dengan tingkat akurasi 93%, precision 95%, recall 95%, dan F1-score 95%. Analisis tren topik dilakukan pada tiga aplikasi *m-banking* populer, yaitu BRImo, BCA mobile, dan Livin' by Mandiri. Pada aplikasi BRImo tren topik yang banyak dibahas adalah terkait dengan biaya dan kecepatan layanan aplikasi. Pada aplikasi BCA mobile tren topik yang dibahas tentang fitur dan kemudahan penggunaan aplikasi. Sementara itu, pada aplikasi Livin' by Mandiri tren topik yang banyak dibahas berkaitan dengan fitur transfer dan jam transaksi.

#### Daftar Rujukan

- [1] A. Ahdiat, "Transaksi Digital Banking di Indonesia Tumbuh 158% dalam 5 Tahun Terakhir," Katadata Media Network. Accessed: Mar. 15, 2024. [Online]. Available: <https://databoks.katadata.co.id/datapublish/2023/07/05/transaksi-digital-banking-di-indonesia-tumbuh-158-dalam-5-tahun-terakhir>
- [2] K. Anam, "Ramai Transaksi Mobile Banking, Bank Mana yang Tumbuh Tinggi?," CNBC Indonesia. Accessed: Mar. 15, 2024. [Online]. Available: <https://www.cnbcindonesia.com/market/20230428090917-17-432962/ramai-transaksi-mobile-banking-bank-mana-yang-tumbuh-tinggi>
- [3] Perhimpunan Bank Nasional, "Lonjakan Transaksi QRIS di 2024: Pertumbuhan Tahunan dan Dampaknya pada Ekonomi Digital." Accessed: Oct. 23, 2024. [Online]. Available: <https://perbanas.org/publikasi/artikel-perbanas/lonjakan-transaksi-qr-is-di-2024-pertumbuhan-tahunan-dan-dampaknya-pada-ekonomi-digital>

- [4] R. N. F. Putri, "Warga Indonesia semakin Gemar Belanja Cashless, BI Catat Transaksi QRIS Tembus Rp 188,36 T pada Kuartal III 2024." Accessed: Oct. 23, 2024. [Online]. Available: <https://www.jawapos.com/finance/015205849/warga-indonesia-semakin-gemar-belanja-cashless-bi-catat-transaksi-qr-is-tembus-rp-18836-t-pada-kuartal-iii-2024>
- [5] I. Ulfi, "Tantangan dan Peluang Kebijakan Non-Tunai: Sebuah Studi Literatur," *Jurnal Ilmiah Ekonomi Bisnis*, vol. 25, no. 1, pp. 55–65, 2020, doi: 10.35760/eb.2020.v25i1.2379.
- [6] Y. B. Adji, W. A. Muhammad, A. N. L. Akrabi, and N. Noerlina, "Perkembangan Inovasi Fintech di Indonesia," *Business Economic, Communication, and Social Sciences Journal (BECOSS)*, vol. 5, no. 1, pp. 47–58, Jan. 2023, doi: 10.21512/becossjournal.v5i1.8675.
- [7] E. B. Yusuf, M. I. Fasa, and Suharto, "Inovasi Layanan Perbankan Syariah Berbasis Teknologi sebagai Wujud Penerapan Green Banking," *Istithmar: Jurnal Studi Ekonomi Syariah*, vol. 7, no. 1, pp. 34–41, Jun. 2022, doi: 10.30762/istithmar.v6i1.33.
- [8] S. Setiawati, "Cashless Makin Digemari, Ini 5 Digital Banking Pilihan Warga RI." Accessed: Sep. 23, 2024. [Online]. Available: <https://www.cnbcindonesia.com/research/20240610063016-128-545113/cashless-makin-digemari-ini-5-digital-banking-pilihan-warga-ri>
- [9] A. Nadira, N. Yudi Setiawan, and W. Purnomo, "Analisis Sentimen Pada Ulasan Aplikasi Mobile Banking Menggunakan Metode Naive Bayes dengan Kamus InSet," *INDEXIA: Informatic and Computational Intelligent Journal*, vol. 5, no. 1, pp. 35–47, 2023, Accessed: Mar. 15, 2024. [Online]. Available: <https://journal.umg.ac.id/index.php/indexia/article/view/5138/3113>
- [10] X. Li, B. Zhang, Z. Zhang, and K. Stefanidis, "A Sentiment-Statistical Approach for Identifying Problematic Mobile App Updates Based on User Reviews," *Information*, vol. 11, no. 3, 2020, doi: 10.3390/info11030152.
- [11] O. Oyeboode, F. Alqahtani, and R. Orji, "Using Machine Learning and Thematic Analysis Methods to Evaluate Mental Health Apps Based on User Reviews," *IEEE Access*, vol. 8, pp. 111141–111158, 2020, doi: 10.1109/ACCESS.2020.3002176.
- [12] C. Jacobi, W. Van Atteveldt, and K. Welbers, "Quantitative analysis of large amounts of journalistic texts using topic modelling," *Digital Journalism*, vol. 4, no. 1, pp. 89–106, 2016, doi: 10.1080/21670811.2015.1093271.
- [13] Direktorat Operasi Keamanan Siber, "LANSKAP KEAMANAN SIBER INDONESIA," 2023. Accessed: Mar. 17, 2024. [Online]. Available: <https://www.bssn.go.id/wp-content/uploads/2024/03/Lanskap-Keamanan-Siber-Indonesia-2023.pdf>
- [14] B. A. Tondang, Muhammad Rizqan Fadhil, Muhammad Nugraha Perdana, Akhmad Fauzi, and Ugra Syahda Janitra, "Analisis pemodelan topik ulasan aplikasi BNI, BCA, dan BRI menggunakan latent dirichlet allocation," *INFOTECH: Jurnal Informatika & Teknologi*, vol. 4, no. 1, pp. 114–127, Jun. 2023, doi: 10.37373/infotech.v4i1.601.
- [15] M. Habibi, A. Priadana, A. Bayu Saputra, and P. Winar Cahyo, "Topic Modelling of Germas Related Content on Instagram Using Latent Dirichlet Allocation (LDA)," 2021.
- [16] H. Kresnawan, S. G. Felle, H. G. Mokay, and N. A. Rakhmawati, "Analyzing Main Topics Regarding The Electronic Information and Transaction Act in Instagram Using Latent Dirichlet Allocation," *Data Science: Journal of Computing and Applied Informatics*, vol. 5, no. 2, pp. 71–84, Jul. 2021, doi: 10.32734/jocai.v5.i2-6125.
- [17] M. Choirul Rahmadan, A. Nizar Hidayanto, D. Swadani Ekasari, B. Purwandari, and Theresiawati, "Sentiment Analysis and Topic Modelling Using the LDA Method related to the Flood Disaster in Jakarta on Twitter," in *2020 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2020, pp. 126–130. doi: 10.1109/ICIMCIS51567.2020.9354320.
- [18] M. Habibi and K. Kusumaningtyas, "Customer Experience Analysis Skincare Products Through Social Media Data Using Topic Modeling and Sentiment Analysis," *Journal of Science and Applied Engineering*, vol. 6, no. 1, p. 1, Jun. 2023, doi: 10.31328/jsae.v6i1.4169.
- [19] K. Amaradiena and T. Widarmanti, "LDA-Topic Modeling: Menggunakan Ulasan Pengguna Untuk Meningkatkan User Experience (Studi pada PeduliLindungi)," *SELKO: Journal of Management & Business*, vol. 6, no. 1, pp. 943–953, 2023, doi: 10.37531/sejaman.v6i1.3802.
- [20] S. Renaldi S, P. Akbar Atmanda, and A. Muhaimin, "Analisis Topic Modelling pada Ulasan Aplikasi Shopee di PlayStore Menggunakan Latent Dirichlet Allocation (LDA)," *Seminar Nasional Sains Data*, 2023.
- [21] B. Pang and L. Lee, "Opinion mining and sentiment analysis," 2008.
- [22] J. Ipmawati, S. Saifulloh, and K. Kusnawi, "Analisis Sentimen Tempat Wisata Berdasarkan Ulasan pada Google Maps Menggunakan Algoritma Support Vector Machine," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 1, pp. 247–256, Jan. 2024, doi: 10.57152/malcom.v4i1.1066.
- [23] J. A. Costales, E. M. Lorico, and C. M. de Los Santos, "A Comparative Sentiment Analysis about HIV and AIDS on Twitter Tweets Using Supervised Machine Learning Approach," in *2023 5th International Conference on Computer Communication and the Internet (ICCCI)*, 2023, pp. 27–32. doi: 10.1109/ICCCI59363.2023.10210162.
- [24] F. Adi Artanto, "Support Vector Machine Berbasis Particle Swarm Optimization Pada Analisis Sentimen Anggota KPPS," *Jurnal Fasilkom*, vol. 14, no. 1, pp. 75–79, Apr. 2024.
- [25] Hidayatunnisa, Kusriani, and Kusnawi, "Perbandingan Kinerja Metode Naive Bayes dan Support Vector Machine dalam Analisis Soal," *Jurnal Fasilkom*, vol. 13, no. 2, pp. 173–180, Aug. 2023.
- [26] D. M. Blei, A. Y. Ng, and M. I. Jordan, "Latent Dirichlet Allocation," *Journal of Machine Learning Research*, vol. 3, pp. 993–1022, 2003.