



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 4 No. 4 (2025) pp: 145-156

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Analisis Perbandingan Kualitas Layanan Digital pada Bank Konvensional dan Bank Digital di Indonesia

Andi Ruslan, Valentino Aris, Muhammad Taufik, Farida Islamiah, Andi Balqis Mutiara Asizah

Jurusan Bisnis dan Kewirausahaan, Fakultas Ekonomi dan Bisnis, Universitas Negeri Makassar

andi.ruslan@unm.ac.id, valentino.aris@unm.ac.id, muh.taufik.b@unm.ac.id, farida.islamiah@unm.ac.id,

balqisandi00@gmail.com

Abstrak

Penelitian ini membandingkan kualitas layanan digital bank konvensional dan bank digital di Indonesia menggunakan social media analysis terhadap 36.000 ulasan Google Play dari Bank Jago, SeaBank, Wonder by BNI, dan MyBCA. Data diproses melalui pembersihan, tokenisasi, dan stemming; pelabelan sentimen berbasis leksikon, lalu diklasifikasikan dengan tiga algoritma (SVM, Naïve Bayes, dan Random Forest) serta dievaluasi menggunakan confusion matrix. Hasilnya, bank digital memperoleh sentimen positif lebih tinggi sebesar 10.618 dibanding bank konvensional sebesar 7.079, sementara keluhan utama di kedua kategori berkisar pada login/registrasi, pembaruan aplikasi, dan kerumitan proses transaksi. SVM menunjukkan kinerja terbaik dengan akurasi ~88% (bank konvensional) dan ~89% (bank digital), diikuti Random Forest dan Naïve Bayes. Temuan ini menegaskan bahwa kualitas layanan digital bank digital relatif lebih unggul, khususnya pada kemudahan penggunaan aplikasi dan ketersediaan fitur transaksi. Namun, terdapat ruang perbaikan yang sama-sama mendesak pada pengalaman awal dan stabilitas fitur inti. Implikasi praktisnya, perbankan perlu memprioritaskan penyederhanaan halaman login dan alur registrasi, serta melakukan pembaruan berkala yang diselaraskan dengan kebutuhan dan umpan balik pengguna untuk meningkatkan kepuasan dan keandalan layanan.

Kata kunci: Social Media Analysis, Kualitas Layanan Digital, Bank Konvensional, Bank Digital, Sentimen Pengguna.

1. Latar Belakang

Bank memiliki peran yang sangat penting terhadap perkembangan perekonomian sebuah negara (Yuliatin, 2012). Posisi bank menjadi sangat vital dalam menggerakkan roda perekonomian, sehingga tidak ada satu negara pun yang tidak memiliki sebuah bank. Bank memiliki peran dalam menyediakan pembiayaan dan jasa terkait pelayanan keuangan. Bank juga berfungsi untuk memobilisasi dana untuk pembangunan ekonomi suatu negara, dengan menghimpun dana dari masyarakat untuk berinvestasi terhadap pembangunan negara. Saat ini, mayoritas bank yang ada di dunia adalah bank konvensional.

Bank konvensional merupakan bank yang melaksanakan kegiatan usaha secara konvensional yang mana dalam kegiatannya memberikan jasa dalam lalu lintas pembayaran berdasarkan prosedur dan ketentuan yang telah ditetapkan (Haryanto et al., 2021). Setiawan menjelaskan bahwa perbankan konvensional memberikan pengaruh yang signifikan terhadap perekonomian Indonesia melalui layanan kredit dan pembiayaan (Setiawan, 2020). Perbankan konvensional juga berperan dalam pengembangan ekonomi masyarakat melalui pembiayaan Usaha Mikro, Kecil, dan Menengah (UMKM) di Indonesia.

Perkembangan teknologi informasi dan komunikasi telah mempengaruhi model bisnis dan lingkungan bisnis sektor perbankan di Indonesia. Pemanfaatan teknologi informasi untuk memberikan layanan digital pada konsumen mulai dilakukan oleh bank konvensional. Bank konvensional dapat memberikan layanan transaksi pembayaran, transfer rekening, melihat histori transaksi, membuat rekening baru secara online, dan masih banyak lagi fitur lainnya secara digital. Layanan digital tersebut dilakukan dengan memanfaatkan teknologi informasi dan komunikasi. Implementasi layanan digital ini kemudian disambut baik oleh konsumen yang memang pada dasarnya telah mengalami pola perilaku transaksi yang berubah dan cenderung ke arah digitalisasi.

Proses transformasi digital di sektor perbankan menyebabkan munculnya model bisnis yang dikenal dengan sebutan bank digital. Bank digital merupakan bank yang berfungsi untuk menyediakan dan menjalankan kegiatan usaha perbankan melalui saluran elektronik tanpa kantor fisik selain kantor pusat atau menggunakan

kantor fisik terbatas (Otoritas Jasa Keuangan Republik Indonesia, 2021). Layanan dan kegiatan usaha yang dilakukan oleh bank digital sepenuhnya dilakukan secara daring. Dengan kata lain, segala bentuk kegiatan nasabah yang sebelumnya dilakukan pada kantor cabang, seperti pembukaan rekening tabungan, deposito, cetak rekening koran, pengajuan kredit, hingga bantuan customer service bisa dilakukan oleh bank digital tanpa harus ada sesi tatap muka secara langsung antara nasabah dan juga pihak bank. Bank digital kemudian disambut dengan sangat baik karena memberikan kemudahan dalam memberikan pelayanan kepada konsumennya.

Data menunjukkan penerimaan terhadap bank digital sudah sangat tinggi. Di Indonesia, jumlah pemilik rekening bank digital di Tanah Air menyentuh 47,7 juta pada 2021 (Finder.com, n.d.). Hal ini menjadikan Indonesia sebagai negara dengan tingkat penetrasi bank digital terbesar kedua di dunia. Data menunjukkan bahwa dari jumlah pengguna tersebut, sebanyak 78 persen penggunaan Indonesia yang aktif menggunakan layanan digital (McKinsey, 2021). Hal ini menunjukkan potensi yang sangat besar untuk layanan bank digital dapat berkembang di Indonesia. Salah satu faktor penting yang mendukung adalah tingginya tingkat transaksi digital di Indonesia, dimana transaksi digital adalah layanan unggulan yang disediakan oleh bank digital.

Tingginya tingkat penerimaan bank digital menyebabkan timbul persaingan dengan bank konvensional. Kedua jenis bank tersebut sudah mulai memanfaatkan teknologi informasi untuk menyediakan layanan digital kepada masyarakat. Pertanyaan utamanya adalah apakah bank konvensional dapat menyediakan layanan digital yang setara atau lebih baik dibandingkan dengan layanan yang disediakan oleh bank digital. Disisi lain, dengan layanan digital yang disediakan oleh bank digital yang sepenuhnya menggunakan teknologi, apakah tidak sebaiknya bank konvensional juga menggunakan strategi dan model bisnis yang sama. Oleh karena itu, pada penelitian ini kami akan mengukur kualitas layanan digital yang dilakukan pada bank konvensional dan bank digital.

Berdasarkan penjelasan diatas, kami tertarik untuk meneliti kualitas layanan digital pada bank konvensional dan bank digital di Indonesia. Data akan diperoleh dari media sosial untuk kemudian dianalisis menggunakan metode social media analysis. Hasil analisis akan memberikan pengetahuan mengenai dimensi-dimensi yang mempengaruhi kualitas layanan digital pada bank konvensional dan bank digital di Indonesia. Informasi dan pengetahuan yang diperoleh dari penelitian ini akan memberikan gambaran pelayanan digital pada dua jenis bank tersebut. Pada penelitian ini, kami akan memperkenalkan metode social media analysis untuk identifikasi dan mengukur dimensi utama kualitas layanan digital pada bank konvensional dan bank digital di Indonesia.

Social media analysis (SMA) adalah seni dan ilmu untuk mengekstrak wawasan tersembunyi yang berharga dari sejumlah besar data media sosial yang semi-terstruktur dan tidak terstruktur untuk memungkinkan pengambilan keputusan yang terinformasi dan berwawasan luas (Khan, 2015). Social media analysis minimal memiliki 7 (lapisan) yang dapat dianalisis. Setiap lapisan ini memiliki informasi dan pengetahuan yang potensial yang dapat di mining untuk memberikan pengetahuan pada bisnis. Setiap lapisan ini memiliki jenis data yang berbeda-beda. Pada penelitian ini akan dilakukan analisis pada lapisan Lapisan text (text layer). Lapisan ini merupakan analisis yang memproses ekstrasi dan analisisnya menggunakan data dengan tipe teks. Jenis datanya dapat berupa komentar pada media sosial, tweet, postingan, tulisan pada blog, dan status pengguna media sosial. Pada social media analysis berbasis teks, umumnya digunakan untuk melihat sentimen, tema, topik, dan kata yang sedang dibicarakan oleh konsumen. Informasi yang diperoleh dari analisis tersebut dapat memberikan gambaran mengenai dimensi-dimensi kualitas layanan yang dianggap penting oleh konsumen.

Penelitian ini akan mengidentifikasi, mengukur, dan membandingkan kualitas layanan pada bank konvensional dan bank digital. Yang membedakan penelitian ini dengan penelitian-penelitian lain adalah penelitian ini yang pertama membandingkan kualitas layanan digital bank konvensional dan bank digital di Indonesia. Pengetahuan mengenai kualitas layanan digital ini diharapkan dapat meningkatkan kualitas layanan digital sektor perbankan di Indonesia. Bank konvensional yang mengadopsi teknologi digital tidak sebesar bank digital dapat belajar dari penerapan teknologi yang dilakukan oleh bank digital, dan sebaliknya. Penelitian ini juga memperkenalkan metode social media analysis (SMA) dimana metode ini dapat mengidentifikasi dimensi-dimensi yang mempengaruhi kualitas layanan berdasarkan komentar dan diskusi yang dilakukan oleh konsumen di media sosial. Selain itu, metode ini dapat menghasilkan sentimen yang dirasakan oleh konsumen terkait dengan kualitas layanan yang diberikan. Dengan pengetahuan ini, perusahaan dapat melakukan perbaikan kualitas layanan kedepannya.

2. Metode Penelitian

Rancangan penelitian yang digunakan pada penelitian ini adalah studi kasus (case study). Pemilihan ini karena desain penelitian studi kasus memungkinkan dilakukannya analisis terhadap suatu fenomena tertentu, identifikasi kemungkinan besar variabel penting dan identifikasi hubungan antara variabel tersebut. Pada penelitian ini akan diidentifikasi dimensi utama yang mempengaruhi kualitas layanan digital pada bank konvensional dan bank digital di Indonesia. Selain itu, juga akan dilakukan perbandingan antara kualitas layanan digital kedua jenis bank tersebut. Oleh karena itu, kami berasumsi bahwa penggunaan studi kasus pada penelitian ini dianggap sudah tepat.

Metode penelitian yang digunakan dalam penelitian ini adalah metode kualitatif dan kuantitatif. Metode penelitian kualitatif dalam penelitian ini digunakan untuk menganalisis percakapan konsumen yang dilakukan pada media sosial mengenai layanan digital yang disediakan oleh bank konvensional dan bank digital di Indonesia. Percakapan ini kemudian akan dianalisis untuk mengetahui dimensi kualitas layanan digital yang dianggap penting oleh konsumen. Data yang digunakan pada penelitian ini adalah data ulasan yang diberikan pengguna mobile banking di bank konvensional dan bank digital. Data ini dapat diperoleh secara online pada google play store dengan menggunakan metode crawling data. Lokasi penelitian ini akan dilakukan di Program Studi Bisnis Digital Fakultas Ekonomi dan Bisnis Universitas Negeri Makassar.

Teknik pengumpulan data adalah metode yang digunakan untuk mengumpulkan informasi yang relevan dengan penelitian. Teknik pengumpulan data yang digunakan pada penelitian ini yaitu:

a. Studi Literatur

Studi literatur (juga dikenal sebagai studi kepustakaan) adalah metode penelitian yang mengandalkan penelusuran dan kajian terhadap literatur (buku, jurnal, artikel, dll) yang relevan dengan topik penelitian untuk mengumpulkan data dan informasi, serta membangun kerangka teori atau hipotesis. Pada penelitian ini studi literatur dilakukan dengan mengumpulkan buku dan penelitian sebelumnya yang berkaitan dengan penelitian.

b. Crawling Data

Crawling data, juga dikenal sebagai web scraping atau web harvesting, adalah proses otomatis untuk mengekstrak informasi dari situs web menggunakan perangkat lunak atau skrip yang disebut crawler atau spider. Tujuan utamanya adalah untuk mengumpulkan data dalam skala besar dari berbagai sumber di internet yang kemudian dapat dianalisis atau digunakan untuk berbagai keperluan, seperti pengindeksan oleh mesin pencari, analisis kompetitor, pengumpulan data untuk riset, atau agregasi konten. Proses ini meniru cara manusia menjelajahi web, namun melakukannya dengan kecepatan dan skala yang jauh lebih besar, memungkinkan pengumpulan data yang efisien dari struktur halaman web yang kompleks (Manning et al., 2009).

Secara teknis, proses crawling dimulai dengan daftar URL awal (seeds) yang diberikan kepada crawler. Crawler kemudian mengunjungi URL tersebut, mengunduh konten halaman (biasanya HTML), dan mem-parsing konten tersebut untuk mengekstrak informasi yang relevan serta URL baru yang tertaut di dalamnya. URL baru ini kemudian ditambahkan ke dalam antrian (frontier) untuk dikunjungi selanjutnya, menciptakan siklus penjelajahan yang berkelanjutan. Crawler harus dirancang untuk menangani berbagai tantangan seperti struktur situs web yang dinamis, konten yang dihasilkan oleh JavaScript, serta menghormati batasan yang ditetapkan oleh file robots.txt yang berisi instruksi bagi web crawler mengenai halaman mana yang boleh dan tidak boleh diakses (Olston & Najork, 2010).

Aplikasi crawling data sangat luas, mulai dari pengindeksan konten untuk mesin pencari agar informasi mudah ditemukan, agregasi berita dari berbagai portal, pemantauan harga produk secara real-time di situs e-commerce, hingga pengumpulan data untuk penelitian akademis di berbagai bidang. Meskipun sangat bermanfaat, praktik crawling data juga menimbulkan pertimbangan etika dan hukum yang signifikan, termasuk isu terkait beban server yang ditimbulkan pada situs target, potensi pelanggaran hak cipta atas konten yang diekstrak, dan masalah privasi jika data pribadi pengguna ikut terkumpul. Oleh karena itu, penting bagi praktisi crawling untuk beroperasi secara bertanggung jawab, menghormati kebijakan situs, dan mempertimbangkan implikasi legal dari aktivitas mereka (Krotov et al., 2020).

Teknik analisis data adalah proses pengolahan data untuk menemukan pola, hubungan, dan informasi yang berguna dari data tersebut. Teknik analisis data yang digunakan dalam penelitian ini adalah:

a. Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin supervise yang kuat, awalnya dikembangkan untuk tugas klasifikasi biner, meskipun telah diperluas untuk klasifikasi multi-kelas dan regresi (dikenal sebagai Support Vector Regression atau SVR). Inti dari SVM adalah menemukan hyperplane optimal yang memisahkan titik data dari kelas yang berbeda dalam ruang fitur dengan margin terbesar. Hyperplane ini adalah batas keputusan, dan margin adalah jarak antara hyperplane dan titik data terdekat dari masing-masing kelas. Titik-titik data yang paling dekat dengan hyperplane dan menentukan posisinya disebut support vectors. Tujuan memaksimalkan margin ini adalah untuk meningkatkan kemampuan generalisasi model, sehingga mengurangi risiko overfitting pada data pelatihan dan meningkatkan performa pada data yang belum pernah dilihat sebelumnya (Cortes & Vapnik, 1995).

Untuk menangani data yang tidak dapat dipisahkan secara linear dalam ruang fitur aslinya, SVM menggunakan teknik yang dikenal sebagai "kernel trick". Kernel trick memungkinkan SVM untuk memetakan data input ke ruang fitur berdimensi lebih tinggi di mana pemisahan linear mungkin terjadi, tanpa perlu secara eksplisit menghitung koordinat data dalam ruang berdimensi tinggi tersebut. Hal ini dicapai dengan menggunakan fungsi kernel (seperti linear, polinomial, radial basis function/RBF, atau sigmoid) yang menghitung produk titik dari vektor dalam ruang fitur berdimensi tinggi hanya berdasarkan vektor asli di ruang input, sehingga secara signifikan mengurangi kompleksitas komputasi. Kemampuan ini membuat SVM sangat fleksibel dan mampu menangani hubungan data yang kompleks dan non-linear secara efisien (Boser et al., 1992).

SVM menawarkan beberapa keunggulan, termasuk efektivitasnya dalam ruang berdimensi tinggi (bahkan ketika jumlah dimensi lebih besar dari jumlah sampel), efisiensi memori karena hanya menggunakan subset titik pelatihan (support vector) dalam fungsi keputusan, dan fleksibilitas melalui berbagai pilihan fungsi kernel yang memungkinkan penyesuaian terhadap berbagai jenis data. Namun, SVM juga memiliki keterbatasan, seperti sensitivitas terhadap pilihan parameter kernel dan parameter regularisasi C (yang mengontrol trade-off antara memaksimalkan margin dan meminimalkan kesalahan klasifikasi), serta kompleksitas komputasi yang bisa tinggi pada dataset yang sangat besar selama fase pelatihan. Meskipun demikian, karena kinerjanya yang solid dan dasar teoretis yang kuat, SVM telah berhasil diterapkan dalam berbagai bidang seperti pengenalan pola, klasifikasi teks, bioinformatika, dan deteksi citra (Burgess, 1998).

b. Naïve Bayes

Naive Bayes adalah algoritma klasifikasi probabilistik yang didasarkan pada Teorema Bayes dengan asumsi independensi yang kuat (sering disebut "naive") antar fitur. Meskipun asumsi ini jarang sepenuhnya benar dalam dunia nyata, algoritma ini seringkali bekerja dengan sangat baik dalam praktik, terutama untuk tugas klasifikasi teks seperti penyaringan spam atau analisis sentimen. Prinsip dasarnya adalah menghitung probabilitas posterior dari setiap kelas, diberikan sekumpulan fitur observasi, dan kemudian memilih kelas dengan probabilitas tertinggi. Secara matematis, untuk sebuah set fitur $X = \{x_1, x_2, \dots, x_n\}$ dan kelas C , probabilitas posterior $P(C|X)$ dihitung sebagai $P(C|X) \propto P(C) * \prod P(x_i|C)$, di mana $P(C)$ adalah probabilitas prior kelas dan $P(x_i|C)$ adalah probabilitas likelihood fitur x_i diberikan kelas C . Asumsi independensi inilah yang menyederhanakan perhitungan $P(X|C)$ menjadi produk dari $P(x_i|C)$ untuk setiap fitur, membuatnya komputasional sangat efisien (Domingos & Pazzani, 1997).

Terdapat beberapa varian Naive Bayes yang disesuaikan dengan jenis data fitur, seperti Gaussian Naive Bayes untuk fitur kontinu yang diasumsikan terdistribusi normal, Multinomial Naive Bayes yang umum digunakan untuk klasifikasi teks dengan fitur berupa frekuensi kata (misalnya, jumlah kemunculan kata dalam dokumen), dan Bernoulli Naive Bayes untuk fitur biner (misalnya, apakah sebuah kata ada atau tidak ada dalam dokumen). Keunggulan utama Naive Bayes terletak pada kesederhanaan komputasionalnya, kebutuhan data pelatihan yang relatif kecil untuk estimasi parameter (probabilitas prior dan likelihood), dan kemampuannya menangani dataset berdimensi tinggi secara efisien. Namun, keterbatasannya muncul dari asumsi independensi fitur yang kaku, yang jika dilanggar secara signifikan dapat menurunkan performa, serta masalah "zero-frequency" (probabilitas nol jika kombinasi fitur-kelas tertentu tidak pernah muncul di data latih), yang biasanya diatasi dengan teknik penghalusan seperti Laplace smoothing (Irina Rish, 2001).

c. Random Forest

Random Forest adalah metode pembelajaran ensemble yang populer, dikembangkan untuk tugas klasifikasi dan regresi, yang beroperasi dengan membangun sejumlah besar pohon keputusan (decision trees) pada waktu pelatihan. Setiap pohon dalam hutan dilatih menggunakan sampel bootstrap (sampling dengan penggantian) dari dataset asli, dan pada setiap node pemisahan (split) dalam pohon, hanya subset acak dari fitur yang dipertimbangkan untuk menemukan pemisahan terbaik. Kombinasi dari bootstrap sampling dan pemilihan fitur acak ini bertujuan untuk mengurangi varians model dan meningkatkan kemampuan generalisasi dengan mendekorrelasi pohon-pohon individu, sehingga menghasilkan model yang lebih robust dan kurang rentan terhadap overfitting dibandingkan dengan satu pohon keputusan tunggal (Breiman, 2001).

Prediksi akhir dari Random Forest diperoleh melalui agregasi hasil dari semua pohon individu: untuk tugas klasifikasi, prediksi kelas yang paling sering muncul (majority vote) dari semua pohon akan dipilih, sedangkan untuk regresi, rata-rata prediksi dari semua pohon digunakan. Algoritma ini menawarkan sejumlah keunggulan, termasuk akurasi yang tinggi, kemampuan menangani data berdimensi besar, ketahanan terhadap overfitting, dan kemampuannya untuk mengukur pentingnya variabel (feature importance) secara internal. Meskipun Random Forest cenderung lebih kompleks secara komputasional dan kurang interpretable dibandingkan satu pohon keputusan, kekuatan prediktifnya dan kemampuannya untuk menangani berbagai jenis data tanpa perlu penskalaan fitur yang ekstensif menjadikannya pilihan populer dalam berbagai aplikasi seperti deteksi penipuan, diagnosa medis, dan pemodelan ekologi (Cutler et al., 2012).

3. Hasil dan Diskusi

Dalam penelitian ini, data dikumpulkan adalah ulasan yang diberikan pengguna terkait aplikasi mobile banking pada platform google play store. Aplikasi mobile banking tersebut mencakup aplikasi bank jago, aplikasi sea bank, aplikasi wonder by BNI, dan aplikasi MyBCA. Proses pengumpulan data menghasilkan 9.000 data ulasan untuk masing-masing aplikasi tersebut, sehingga total data yang diperoleh adalah 36.000 data. Data tersebut mencakup berbagai atribut yang relevan untuk analisis sentimen. Adapun rincian kolom data yang dikumpulkan adalah sebagai berikut:

Tabel 1. Hasil Pengumpulan Data dari Google Play Store

Kolom	Jumlah Data	Tipe Data	Deskripsi
User Name	36.000	Text	Nama pengguna yang mengakses play store
Score	36.000	INT	Nilai ulasan yang diberikan pengguna
At	36.000	Text	Tanggal pengguna memberikan ulasan
Contect	36.000	Text	Ulasan yang diberikan pengguna
thumbsUpCount	36.000	INT	Jumlah likes dari ulasan yang diberikan pengguna

Sumber: Peneliti (2025)

Persiapan data adalah langkah penting dalam proses pengolahan data. Tujuannya untuk membersihkan data yang tidak relevan dan meningkatkan performa analisis. Tahap ini terdiri dari beberapa langkah dan dibantu dengan alat Python. Berikut adalah tahapan persiapan data yang dilakukan dalam penelitian ini:

a. Data Cleaning

Tahap pembersihan data melibatkan penghapusan data duplikat atau kata-kata yang memiliki kalimat salinan yang sama dalam satu kumpulan data yang telah diperoleh dan juga penghapusan pada data dalam kolom yang kosong. Data mentah yang diperoleh setelah proses pengambilan data berjumlah 36.000 ulasan. Setelah proses pembersihan data, diperoleh 34.939 ulasan yang bersih dan akan digunakan.

b. Cleansing

Cleansing adalah langkah awal dalam mempersiapkan data untuk analisis lebih lanjut. Pada tahap ini, data mentah dibersihkan dari unsur- unsur yang tidak diperlukan. Ini termasuk menghapus tautan, tagar, spesial karakter tanda baca, angka, serta karakter-karakter khusus lainnya yang tidak berkontribusi pada analisis sentimen. Proses pembersihan ini penting untuk memastikan bahwa data yang dianalisis adalah teks yang relevan dan bersih.

c. Case Folding

Case folding adalah proses mengubah semua karakter dalam teks menjadi huruf kecil. Langkah ini diperlukan untuk menghindari perbedaan antara kata-kata yang sama yang ditulis dalam huruf besar dan kecil. Misalnya,

"Layanan" dan "layanan" akan dianggap sebagai kata yang sama setelah case folding. Dengan melakukan ini, variasi kasus tidak akan mempengaruhi analisis sentimen.

d. Tokenization

Tokenization adalah proses memecah teks menjadi unit-unit yang lebih kecil yang disebut token. Token dapat berupa kata, frasa, atau simbol lain yang memiliki makna tertentu. Dalam konteks analisis teks, token biasanya berupa kata-kata individu. Misalnya, kalimat "Mantap dan mudah digunakan" akan dipecah menjadi token-token: ["mantap", "dan", "mudah", "digunakan"]. Langkah ini memudahkan analisis sentimen dengan memperlakukan setiap token sebagai unit analisis.

e. Filtering

Filtering adalah proses menghilangkan kata-kata yang tidak memiliki nilai informasi yang signifikan untuk analisis. Kata-kata ini dikenal sebagai stopwords, seperti "dan", "atau", "tetapi", yang umumnya tidak membawa makna sentimen. Filtering membantu dalam mengurangi jumlah data yang perlu diproses dan meningkatkan akurasi model dengan fokus pada kata-kata yang lebih relevan.

f. Stemming

Stemming adalah proses mengurangi kata-kata ke bentuk dasarnya atau akarnya. Tujuannya adalah untuk menghapus akhiran dari kata-kata yang berbeda tetapi memiliki akar yang sama, sehingga dapat dianggap sebagai satu token yang sama. Misalnya, kata-kata "dibuka", "pembayaran", dan "membantu" akan dikurangi menjadi "buka", "bayar" dan "bantu". Stemming membantu mengurangi dimensi data dan meningkatkan kinerja analisis sentimen. Adapun preview hasil dari tahapan cleansing sampai dengan stemming dapat dilihat pada gambar berikut:

	original	cleansing	Tokenization and Case Folding	stopwords	stemming_bata
0	saya heran sda apa dngat wonder saya sapa lla..	saya heran sda apa dngat wonder saya sapa lla..	[saya, heran, sda, apa, dngat, wonder, saya, ..]	[heran, wonder, tranah, sddh, hddh, mndut, ..]	heran wonder tranah sddh fddh mndut sapa ..
1	sangat mudah dan membantu saku dalam semua l..	sangat mudah dan membantu saku dalam semua l..	[sangat, mudah, dan, membantu, saku, dalam, ..]	[mudah, membantu, tranahs]	mudah bantu tranahs
2	aman saat login tidak ada pihm lla..	aman saat login tidak ada pihm lla..	[aman, saat, login, tidak, ada, pihm, lla..]	[aman, login, tidak, ada, pihm, sa..]	aman login tidak ada pihm sa..
3	Har ny Masi surang nih min panantik Indonesia..	Har ny Masi surang nih min panantik Indonesia..	[Har, ny, masi, surang, nih, min, panantik, Indonesia, ..]	[Har, masi, nih, panantik, Indonesia, g, ah, ..]	Har masi nih min panantik g ahwah har sa..
4	Kali, untuk pembayaran PBB belum lengkap yah lla..	Kali, untuk pembayaran PBB belum lengkap yah lla..	[Kali, untuk, pembayaran, PBB, belum, lengkap, yah, lla, ..]	[kai, pembayar, pbb, lengkap, lla, semang, ..]	kai bayar pbb lengkap lla semang rumpang di..
5	Mantap dan mudah digunakan	Mantap dan mudah digunakan	[mantap, dan, mudah, digunakan]	[mantap, modif]	mantap mudah
6	Sempat kawati karna lupa password akun wonder ..	Sempat kawati karna lupa password akun wonder ..	[sempat, kawati, karna, lupa, password, akun, wonder, ..]	[kawati, karna, lupa, password, akun, wonder, ..]	kawati karna lupa password akun wonder anjung ..
7	jd downgrade dari apa DIA mobile banking jd ..	jd downgrade dari apa DIA mobile banking jd ..	[jd, downgrade, dari, apa, DIA, mobile, banking, jd, ..]	[jd, downgrade, apa, dri, mobile, banking, di, ..]	jd downgrade apa dri mobile banking dri dri ..
8	bilang ni kenapa ga bisa register terus lla..	bilang ni kenapa ga bisa register terus lla..	[bilang, ni, kenapa, ga, bisa, register, terus, lla, ..]	[bilang, register, kenapa, kenapa, kenapa, ..]	bilang register kenapa kenapa kenapa dri dri dri ..
9	Bekasng saat dibuka sering lag karna saku lla..	Bekasng saat dibuka sering lag karna saku lla..	[bekasng, saat, dibuka, sering, lag, karna, sa, ..]	[druka, lag, jani, sering, lag, smpat, la, ..]	laga lag jani sering lag smpat laga

Gambar 1. Hasil Cleansing sampai dengan Stemming

g. Pelabelan Data

Pelabelan data adalah tahap di mana setiap ulasan atau teks diberikan label yang sesuai dengan sentimen yang dikandungnya, seperti positif atau negatif. Dalam penelitian ini, pelabelan data dilakukan menggunakan metode kamus lexicon dengan Python. Metode ini melibatkan penggunaan daftar kata atau frasa yang sudah diberi nilai sentimen. Setiap token dalam teks dibandingkan dengan kamus lexicon ini, dan nilai sentimen yang sesuai diberikan. Hasilnya didapatkan 17.697 sentimen positif dan 17.242 sentimen negatif.

Tahap berikutnya, dilakukan Visualisasi dilakukan untuk setiap klasifikasi kelas sentimen. Tujuan dari visualisasi sendiri adalah untuk menampilkan kata-kata rating yang sering diucapkan pengguna. Selain itu, dengan mengekstraksi ulasan ini, visualisasi dapat mengungkapkan informasi baru dari data ulasan. Proses ini dilakukan untuk menyempurnakan informasi yang diperoleh dari proses analisis sentimen.

a. Bank Konvensional

Pada bagian ini, akan diperlihatkan hasil analisis sentimen ulasan pengguna terhadap layanan pada platform digital yang digunakan pada bank konvensional. Platform digital tersebut antara lain Wonder ByBNI dan MyBCA.

1. Ulasan Positif

Gambar 2 merupakan wordcloud yang menunjukkan asosiasi kata dari ulasan dengan sentimen positif. Wordcloud ini membantu kita memahami topik dan kata-kata kunci yang sering muncul dalam diskusi positif. Kata-kata yang lebih besar menunjukkan frekuensi yang lebih tinggi dalam tweet.



Gambar 2. Visualisasi Ulasan Positif dengan Wordcloud

Dari visualisasi ini, terlihat jelas bahwa kata "transaksi" dan "aplikasi" adalah yang paling menonjol, menunjukkan bahwa percakapan transaksi dan aplikasi yang digunakan. Nama merek seperti "bca" dan "bni" juga sering disebut, menandakan apresiasi terhadap layanan kedua bank tersebut. Selain itu, kata-kata seperti "login", "bagus", dan "fitur" menonjol yang menunjukkan pengguna sangat positif terhadap layanan yang diberikan pada mobile banking.

2. Ulasan Negatif

Gambar 3 merupakan wordcloud yang menunjukkan asosiasi kata dari ulasan dengan sentimen negatif. Wordcloud ini membantu kita memahami topik dan kata-kata kunci yang sering muncul dalam diskusi negatif. Kata-kata yang lebih besar menunjukkan frekuensi yang lebih tinggi dalam ulasan.



Gambar 3. Visualisasi Ulasan Negatif dengan Wordcloud

Dari visualisasi ini, terlihat bahwa kata "aplikasi" dan "login" adalah yang paling menonjol, menunjukkan bahwa banyak keluhan terkait dengan performa aplikasi ketika melakukan login. Nama merek seperti "bca" menandakan adanya ketidakpuasan atau masalah yang dialami pengguna ketika akan mengakses mobile banking khususnya BCA. Selain itu, kata-kata seperti "masuk", "daftar", dan "update" menonjol yang menunjukkan pengguna sangat negatif terhadap layanan yang diberikan pada mobile banking.

b. Bank Digital

Pada bagian ini, akan diperlihatkan hasil analisis sentimen ulasan pengguna terhadap layanan pada platform digital yang digunakan pada bank digital. Platform digital tersebut antara lain Bank Jago dan Sea Bank.

1. Ulasan Positif

Gambar 4 merupakan wordcloud yang menunjukkan asosiasi kata dari ulasan dengan sentimen positif. Wordcloud ini membantu kita memahami topik dan kata-kata kunci yang sering muncul dalam diskusi positif. Kata-kata yang lebih besar menunjukkan frekuensi yang lebih tinggi dalam tweet.



Gambar 4. Visualisasi Ulasan Positif dengan Wordcloud

Dari visualisasi ini, terlihat jelas bahwa kata "transaksi", "bank" dan "jago" adalah yang paling menonjol, menunjukkan bahwa percakapan sebahagian didominasi mengenai transaksi yang dilakukan pada bank jago. Nama merek seperti "bank jago" dan "seabank" juga sering disebut, menandakan apresiasi terhadap layanan kedua bank tersebut. Selain itu, kata-kata seperti "aplikasi", "saldo", dan "mudah" menonjol yang menunjukkan pengguna sangat positif terhadap layanan yang diberikan pada aplikasi mobile banking.

2. Ulasan Negatif

Gambar 5 merupakan wordcloud yang menunjukkan asosiasi kata dari ulasan dengan sentimen negatif. Wordcloud ini membantu kita memahami topik dan kata-kata kunci yang sering muncul dalam diskusi negatif. Kata-kata yang lebih besar menunjukkan frekuensi yang lebih tinggi dalam ulasan.



Gambar 5. Visualisasi Ulasan Negatif dengan Wordcloud

Dari visualisasi ini, terlihat bahwa kata "aplikasi", "login", dan "daftar" adalah yang paling menonjol, menunjukkan bahwa banyak keluhan terkait dengan performa aplikasi ketika melakukan login dan daftar. Nama merek seperti "seabank" menandakan adanya ketidakpuasan atau masalah yang dialami pengguna ketika akan mengakses mobile banking khususnya Sea Bank. Selain itu, kata-kata seperti "masuk", "login", dan "ribet" menonjol yang menunjukkan pengguna sangat negatif terhadap layanan yang diberikan pada mobile banking.

Dalam penelitian ini, peneliti akan menggunakan 3 algoritma machine learning untuk menganalisis. Untuk memastikan hasil yang akurat dan dapat diandalkan, peneliti akan melakukan tiga kali percobaan dengan berbagai pembagian data. Visualisasi dilakukan untuk setiap klasifikasi kelas sentimen. Tujuan dari visualisasi sendiri adalah untuk menampilkan kata-kata rating yang sering diucapkan.

a. Analisis Klasifikasi Pada Algoritma Support Vector Machine (SVM)

Pengolahan data untuk bank konvensional dengan perbandingan 80% data latih dan 20% data uji menggunakan algoritma SVM menghasilkan akurasi sebesar 87,62% dengan hasil evaluasi performa model klasifikasi dengan menggunakan Confusion Matrix sebagai berikut :

Tabel 2. Hasil Klasifikasi SVM Bank Konvensional

Class	Precision	Recall	F1-Score	Support
Negative	0.88	0.91	0.90	2056
Positive	0.86	0.83	0.85	1426
Accuracy			0.88	3482
Macro Avg	0.87	0.87	0.87	3482
Weighted Avg	0.88	0.88	0.88	3482

Sumber: Data diolah (2025)

Hasil klasifikasi menggunakan SVM dengan pembagian data 80:20 menunjukkan performa yang berbeda antara kategori sentimen negatif dan positif. Untuk sentimen negatif, model SVM mencapai precision sebesar 0.88, recall 0.91, dan F1-score 0.90 dari total 2.056 data. Sementara untuk sentimen positif, precision mencapai 0.86, recall 0.83, dan F1-score 0.85 dari 1.426 data. Secara keseluruhan, akurasi model adalah 0.88 dengan Macro Average untuk precision, recall, dan F1-score masing-masing sebesar 0.87, 0.87, dan 0.87. Weighted Average untuk precision, recall, dan F1-score adalah 0.88, 0.88, dan 0.88 dari total 3.482 data.

Pengolahan data untuk bank digital dengan perbandingan 80% data latih dan 20% data uji menggunakan algoritma SVM dengan MultinomialNB menghasilkan akurasi sebesar 89,33% dengan hasil evaluasi performa model klasifikasi dengan menggunakan Confusion Matrix sebagai berikut :

Tabel 3. Hasil Klasifikasi SVM Bank Digital

Class	Precision	Recall	F1-Score	Support
Negative	0.88	0.84	0.86	1387
Positive	0.90	0.93	0.91	2120
Accuracy			0.89	3507
Macro Avg	0.89	0.88	0.89	3507
Weighted Avg	0.89	0.89	0.89	3507

Sumber: Data diolah (2025)

Hasil klasifikasi menggunakan SVM dengan pembagian data 80:20 menunjukkan performa yang berbeda antara kategori sentimen negatif dan positif. Untuk sentimen negatif, model SVM mencapai precision sebesar 0.88, recall 0.84, dan F1-score 0.86 dari total 1.387 data. Sementara untuk sentimen positif, precision mencapai 0.90, recall 0.93, dan F1-score 0.91 dari 2.120 data. Secara keseluruhan, akurasi model adalah 0.89 dengan Macro Average untuk precision, recall, dan F1-score masing-masing sebesar 0.89, 0.88, dan 0.89. Weighted Average untuk precision, recall, dan F1-score adalah 0.89, 0.89, dan 0.89 dari total 3.507 data.

b. Analisis Klasifikasi Pada Algoritma Naïve Bayes

Pengolahan data untuk bank konvensional dengan perbandingan 80% data latih dan 20% data uji menggunakan algoritma Naïve Bayes menghasilkan akurasi sebesar 76,42% dengan hasil evaluasi performa model klasifikasi dengan menggunakan Confusion Matrix sebagai berikut :

Tabel 4. Hasil Klasifikasi Naïve Bayes Bank Konvensional

Class	Precision	Recall	F1-Score	Support
Negative	0.76	0.88	0.82	2056
Positive	0.77	0.60	0.68	1426
Accuracy			0.76	3482
Macro Avg	0.77	0.74	0.75	3482
Weighted Avg	0.77	0.76	0.76	3482

Sumber: Data diolah (2025)

Hasil klasifikasi menggunakan Naïve Bayes dengan pembagian data 80:20 menunjukkan performa yang berbeda antara kategori sentimen negatif dan positif. Untuk sentimen negatif, model Naïve Bayes mencapai precision sebesar 0.76, recall 0.88, dan F1-score 0.81 dari total 2.056 data. Sementara untuk sentimen positif, precision mencapai 0.77, recall 0.60, dan F1-score 0.68 dari 1.426 data. Secara keseluruhan, akurasi model adalah 0.76 dengan Macro Average untuk precision, recall, dan F1-score masing-masing sebesar 0.77, 0.74, dan 0.75. Weighted Average untuk precision, recall, dan F1-score adalah 0.77, 0.76, dan 0.76 dari total 3.482 data.

Pengolahan data untuk bank digital dengan perbandingan 80% data latih dan 20% data uji menggunakan algoritma Naïve Bayes dengan menghasilkan akurasi sebesar 77,04% dengan hasil evaluasi performa model klasifikasi dengan menggunakan Confusion Matrix sebagai berikut :

Tabel 5. Hasil Klasifikasi Naïve Bayes Bank Digital

Class	Precision	Recall	F1-Score	Support
Negative	0.78	0.59	0.67	1387
Positive	0.77	0.89	0.82	2120
Accuracy			0.77	3507
Macro Avg	0.77	0.74	0.75	3507
Weighted Avg	0.77	0.77	0.76	3507

Sumber: Data diolah (2025)

Hasil klasifikasi menggunakan Naïve Bayes dengan pembagian data 80:20 menunjukkan performa yang berbeda antara kategori sentimen negatif dan positif. Untuk sentimen negatif, model Naïve Bayes mencapai precision sebesar 0.78, recall 0.59, dan F1-score 0.67 dari total 1.387 data. Sementara untuk sentimen positif, precision mencapai 0.77, recall 0.89, dan F1-score 0.82 dari 2.120 data. Secara keseluruhan, akurasi model adalah 0.77 dengan Macro Average untuk precision, recall, dan F1-score masing-masing sebesar 0.77, 0.74, dan 0.75. Weighted Average untuk precision, recall, dan F1-score adalah 0.77, 0.76, dan 0.76 dari total 3.507 data.

c. Analisis Klasifikasi Pada Algoritma Random Forest

Pengolahan data untuk bank konvensional dengan perbandingan 80% data latih dan 20% data uji menggunakan algoritma Random Forest menghasilkan akurasi sebesar 79,78% dengan hasil evaluasi performa model klasifikasi dengan menggunakan Confusion Matrix sebagai berikut :

Tabel 6. Hasil Klasifikasi Random Forest Bank Konvensional

Class	Precision	Recall	F1-Score	Support
Negative	0.80	0.88	0.84	2056
Positive	0.79	0.69	0.74	1426
Accuracy			0.80	3482
Macro Avg	0.80	0.78	0.79	3482
Weighted Avg	0.80	0.80	0.80	3482

Sumber: Data diolah (2025)

Hasil klasifikasi menggunakan Random Forest dengan pembagian data 80:20 menunjukkan performa yang berbeda antara kategori sentimen negatif dan positif. Untuk sentimen negatif, model Random Forest mencapai precision sebesar 0.80, recall 0.88, dan F1-score 0.84 dari total 2.056 data. Sementara untuk sentimen positif, precision mencapai 0.79, recall 0.69, dan F1-score 0.74 dari 1.426 data. Secara keseluruhan, akurasi model adalah 0.80 dengan Macro Average untuk precision, recall, dan F1-score masing-masing sebesar 0.80, 0.78, dan 0.78. Weighted Average untuk precision, recall, dan F1-score adalah 0.80, 0.80, dan 0.80 dari total 3.482 data.

DOI: <https://doi.org/10.31004/riggs.v4i4.3188>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

Pengolahan data untuk bank digital dengan perbandingan 80% data latih dan 20% data uji menggunakan algoritma Random Forest dengan menghasilkan akurasi sebesar 82,14% dengan hasil evaluasi performa model klasifikasi dengan menggunakan Confusion Matrix sebagai berikut:

Tabel 7. Hasil Klasifikasi Random Forest Bank Digital

Class	Precision	Recall	F1-Score	Support
Negative	0.79	0.74	0.77	1387
Positive	0.84	0.88	0.86	2120
Accuracy			0.82	3507
Macro Avg	0.82	0.81	0.81	3507
Weighted Avg	0.82	0.82	0.82	3507

Sumber: Data diolah (2025)

Hasil klasifikasi menggunakan Random Forest dengan pembagian data 80:20 menunjukkan performa yang berbeda antara kategori sentimen negatif dan positif. Untuk sentimen negatif, model Random Forest mencapai precision sebesar 0.79, recall 0.74, dan F1-score 0.77 dari total 1.387 data. Sementara untuk sentimen positif, precision mencapai 0.84, recall 0.88, dan F1-score 0.86 dari 2.120 data. Secara keseluruhan, akurasi model adalah 0.82 dengan Macro Average untuk precision, recall, dan F1-score masing-masing sebesar 0.82, 0.81, dan 0.81. Weighted Average untuk precision, recall, dan F1-score adalah 0.82, 0.82, dan 0.82 dari total 3.507 data.

Persepsi dan sentimen pengguna terhadap layanan yang disediakan sektor perbankan melalui aplikasi mobile banking menunjukkan pandangan yang umumnya positif. Berdasarkan penelitian yang telah dilakukan sebagian besar pengguna menyukai layanan yang disediakan sektor perbankan melalui aplikasi mobile banking, dengan menyoroti manfaat seperti mudah, bagus, cepat, dan fitur. Sentimen positif ini menunjukkan bahwa pengguna aplikasi mobile banking sebagai bentuk layanan digital yang diberikan oleh sektor perbankan sudah puas dengan layanan yang diberikan. Namun, tentunya masih ada beberapa tantangan yang dihadapi dalam penggunaan aplikasi mobile banking untuk layanan digital sektor perbankan. Tantang tersebut antara lain pengguna masih kerepotan dalam menggunakan aplikasi untuk masuk ke dalam aplikasi dan mendaftar untuk menggunakan aplikasi. Selain itu, banyak pengguna yang masih mengeluhkan penggunaan yang ribet dan mengalami pemotongan biaya tanpa transaksi yang terselesaikan.

Penelitian ini juga melakukan analisis terpisah pada perbankan konvensional dan perbankan digital. Hasil analisis menunjukkan bahwa sentimen positif pada bank konvensional lebih sedikit dibandingkan dengan bank digital. Bank konvensional memiliki sentimen positif pengguna sebanyak 7.079, sedangkan bank digital memiliki sentimen positif pengguna sebanyak 10.618. Hal ini menunjukkan bahwa kualitas layanan digital yang diberikan pada perbankan digital jauh lebih baik dibandingkan dengan perbankan konvensional. Pada perbankan digital, keyword yang terkait dengan sentimen positif yaitu “transaksi”, “aplikasi”, “mudah”, “saldo”, “transfer”, “bagus”, dan “bayar”. Dapat dikatakan bahwa pengguna telah merasa layanan digital yang diberikan oleh perbankan digital pada aplikasi untuk melakukan transaksi perbankan sudah sangat baik.

Hasil analisis juga menunjukkan bahwa sentimen negatif pada perbankan konvensional lebih tinggi dibandingkan dengan perbankan digital. Sentimen negatif pada perbankan konvensional sebanyak 10.328 sedangkan sentimen negatif pada perbankan digital sebanyak 6.914. Hasil ini menunjukkan bahwa perbankan konvensional masih harus membenahi layanan digital yang disediakan kepada pelanggannya. Adapun keyword yang sering muncul terkait dengan sentimen negatif pada perbankan konvensional yaitu “login”, “masuk”, “update”, “ribet”, “susah”, “tolong”, “daftar”, dan “transaksi”. Dapat dikatakan bahwa pengguna layanan digital perbankan konvensional mengeluhkan proses login dan pendaftaran yang ribet dan sulit dilakukan pada aplikasi mobile banking. Selain itu, pelanggan juga mengeluhkan kesulitan dan ribet ketika melakukan transaksi pada aplikasi. Hal ini butuh menjadi perhatian untuk peningkatan kualitas layanan digital pada perbankan konvensional dan perbankan digital.

4. Kesimpulan

Berdasarkan hasil analisis penelitian ini, dapat disimpulkan bahwa metode *social media analysis* berhasil menghasilkan dimensi atau indikator kualitas layanan digital pada bank konvensional dan bank digital di Indonesia; analisis juga menunjukkan bahwa bank digital memberikan kualitas layanan digital yang lebih baik dibandingkan bank konvensional; dan dimensi/indikator yang dimaksud meliputi kemudahan penggunaan aplikasi serta ketersediaan fitur-fitur untuk melakukan transaksi perbankan. Berdasarkan hasil analisis, disarankan agar

bank konvensional maupun bank digital melakukan perbaikan pada fitur login dengan menghadirkan halaman masuk yang sederhana, cepat, dan tidak berbelit; menyediakan proses registrasi yang mudah dan intuitif sebagai gerbang awal sebelum pengguna melanjutkan penggunaan aplikasi; serta melakukan pembaruan aplikasi secara berkala yang diselaraskan dengan kebutuhan serta umpan balik pengguna guna meningkatkan kualitas layanan digital.

Referensi

1. Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). Training algorithm for optimal margin classifiers. *Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory*, 144–152. <https://doi.org/10.1145/130385.130401>
2. Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
3. Burges, C. J. C. (1998). A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2(2), 121–167. <https://doi.org/10.1023/A:1009715923555>
4. Cortes, C., & Vapnik, V. (1995). Natural vibration response based damage detection for an operating wind turbine via Random Coefficient Linear Parameter Varying AR modelling. *Machine Learning*, 628(1), 273–297. <https://doi.org/10.1088/1742-6596/628/1/012073>
5. Cutler, A., Cutler, D. R., & Stevens, J. R. (2012). Random Forests. In C. Zhang & Y. Ma (Eds.), *Ensemble Machine Learning: Methods and Applications* (pp. 157–175). Springer New York. https://doi.org/10.1007/978-1-4419-9326-7_5
6. Domingos, P., & Pazzani, M. (1997). On the Optimality of the Simple Bayesian Classifier under Zero-One Loss. *Machine Learning*, 29(2), 103–130. <https://doi.org/10.1023/A:1007413511361>
7. Finder.com. (n.d.). *Data Jumlah Pemilik Akun atau Rekening Bank Digital di Indonesia*. 2021.
8. Haryanto, D., Maruapey, H., & Sudarsa, A. S. (2021). Implementasi Kebijakan Intensif Roleplay Customer Service dan Pengaruhnya terhadap Kualitas Pelayanan Nasabah di Kantor PT. Bank Tabungan Negara (Persero) Tbk. Cabang Bogor. *Jurnal Ilmiah Akuntansi Dan Keuangan*, 4(4), 1312–1321.
9. Irina Rish. (2001). An empirical study of the naive Bayes classifier. *IJCAI 2001 Workshop on Empirical Methods in Artificial Intelligence*, 3(22).
10. Khan, G. F. (2015). Seven Layers of Social Media Analytics: Mining Business Insight from Social Media Text, Actions, Networks, Hyperlinks, Apps, Search Engine, and Location Data. In *CreateSpace Independent Publishing Platform* (Vol. 1). <http://7layersanalytics.com/>
11. Krotov, V., Johnson, L., & Silva, L. (2020). Tutorial: Legality and ethics of web scraping. *Communications of the Association for Information Systems*, 47(1), 539–563. <https://doi.org/10.17705/1CAIS.04724>
12. Manning, C. D., Raghavan, P., & Schütze, H. (2009). Introduction to Modern Information Retrieval (2nd edition). In *Cambridge University Press*. <https://doi.org/10.1108/00242530410565256>
13. McKinsey. (2021). *The Future of Financial Service*.
14. Olston, C., & Najork, M. (2010). Web Crawling. *Foundations and Trends in Information Retrieval*, 4(3), 175–246. <https://doi.org/10.1561/15000000017>
15. Otoritas Jasa Keuangan Republik Indonesia. (2021). *Kebijakan Dalam Menjaga Kinerja Dan Stabilitas Pasar Modal Akibat Penyebaran Corona Virus Disease 2019*.
16. Setiawan, I. (2020). Analisis Peran Perbankan terhadap Pertumbuhan Ekonomi di Indonesia: Bank Syariah Versus Bank Konvensional. *JURNAL AKUNTANSI, EKONOMI Dan MANAJEMEN BISNIS*, 8(1), 52–60. <https://doi.org/10.30871/jaemb.v8i1.1649>
17. Yuliatin, Y. (2012). Perbankan dalam Dimensi Konvensional dan Syariah. *NALAR FIQH: Jurnal Hukum Islam*, 5(2). <https://doi.org/10.30631/nf.v5i2.1239>