

BAB II TINJAUAN PUSTAKA

Bab ini membahas teori-teori utama dan pendukung yang menjadi landasan dalam menganalisis sentimen dan jaringan graf atas reaksi publik terhadap Putusan Mahkamah Konstitusi Nomor 60/PUU-XXII/2024 di media sosial, dengan menggunakan pendekatan berbasis algoritma logaritmik. Kajian ini melibatkan tiga pendekatan analitis utama, yaitu:

1. Analisis sentimen;
2. *Social Network Analysis*;
3. *Graph Network Analysis*;
4. *Naïve Bayes Classifier*.
5. *Support Vector Machine (SVM)*

2.1 Teori Utama

2.1.1 Analisis Sentimen

Analisis sentimen merupakan cabang dari *Natural Language Processing (NLP)* yang berfokus pada proses otomatis dalam mengekstraksi dan menggali opini dari suatu teks. Bidang ini fokus mempelajari sentimen, opini, sikap, dan emosi yang terkandung dalam sebuah teks terhadap subjek tertentu. Analisis sentimen menggunakan konsep klasifikasi yang selanjutnya dikategorikan menjadi 3 jenis kelas yaitu, netral, positif, dan negatif. Analisis sentimen ini menjadi bidang penelitian yang berkembang pesat, dikarenakan oleh penggunaan media sosial dimasyarakat juga menjadi lebih intensif. Studi mengenai analisis sentimen mempunyai dampak besar pada banyak bidang lain seperti manajemen, politik, sains, ekonomi, dan ilmu sosial. Implementasi dari analisis sentimen juga sangat beragam, tetapi secara umum implementasi pada bidang ini dilakukan dengan teknik *supervised machine learning*, *unsupervised*, dan juga analisis *lexicon based*.

Analisis sentimen merupakan suatu metode yang memanfaatkan pemrosesan bahasa alami (*NLP*), analisis teks, dan teknik linguistik komputasional untuk mendeteksi serta mengambil informasi bersifat subjektif dari suatu teks. “Analisis sentimen atau opini mining bertujuan untuk mengidentifikasi sentimen

emosi, atau pendapat dalam teks” (Liu 2012 dalam Fahrezi 2024). Menurut Penelitian yang dilakukan oleh wibowo (2019), analisis sentimen adalah suatu metode mengekstraksi data teks dengan tujuan memperoleh informasi mengenai sentimen yang bisa berupa positif, netral, atau negatif (Wibowo et al., 2019)

Analisis sentimen dapat dilakukan dengan berbagai metode yang umumnya dikelompokkan menjadi pendekatan *lexicon based* dan pendekatan berbasis *machine learning*. Pendekatan yang menggunakan machine learning mencakup proses pelatihan model dengan data agar mampu mengenali pola tertentu dalam tugas yang ditargetkan dengan data set berlabel, yang memungkinkan identifikasi pola sentimen dalam teks dengan akurasi yang lebih tinggi.

Penelitian ini menggunakan analisis sentimen untuk mengelompokkan reaksi publik yang muncul setelah Putusan Mahkamah Konstitusi diputuskan dan diumumkan. Reaksi tersebut dikategorikan ke dalam tiga kelompok utama, yaitu positif, negatif, dan netral. Dengan memanfaatkan pemrosesan data dengan bahasa alami *Natural Language Processing (NLP)*, penulis berharap dapat menelusuri ekspresi emosi dan pendapat yang terkandung dalam sebuah unggahan di media sosial. Penerapan algoritma seperti *Naïve Bayes Classifier* dapat digunakan untuk meningkatkan akurasi dalam proses klasifikasi sentimen. Metode ini juga berfungsi untuk mengungkap sebaran sentimen positif dan negatif di lingkungan media sosial. Analisis sentimen sendiri merupakan salah satu bidang dalam pemrosesan bahasa alami *Natural Language Processing (NLP)* yang bertujuan memahami opini, sikap, dan emosi yang terkandung dalam suatu teks. Dalam konteks media sosial, analisis ini digunakan untuk mengidentifikasi persepsi publik terhadap suatu peristiwa atau kebijakan tertentu, seperti dalam penelitian ini adalah Putusan Mahkamah Konstitusi Nomor. 60/PUU-XXII/2024 diterima dikalangan masyarakat.

2.1.2 Social Network Analysis

Social Network Analysis (SNA) adalah metode pemodelan yang merepresentasikan individu sebagai simpul (*nodes*) dan hubungan atau interaksi antar individu sebagai garis penghubung (*edges*). Pendekatan ini memungkinkan pemahaman yang lebih dalam mengenai pola interaksi sosial dalam suatu komunitas atau individu (Sapountzi & Psannis, 2016). *SNA* juga bermanfaat dalam

mengkaji struktur jaringan yang melibatkan organisasi, gagasan, maupun individu yang saling terhubung dalam suatu ekosistem sosial. (Oktora dan Alamsyah, 2014 dalam Brastawisnu 2018).

2.1.2.1 Properti Jaringan pada *Social Network Analysis*

Social Network Analysis (SNA) memiliki sejumlah karakteristik jaringan yang dapat dimanfaatkan untuk memetakan hubungan antar elemen, yang pada akhirnya berkontribusi dalam pengembangan manajemen pengetahuan dalam organisasi (Alamsyah, 2013 dalam Brastawisnu 2018). Beberapa elemen penting dalam properti jaringan SNA meliputi *nodes*, *edges*, rata-rata derajat (*average degree*), diameter jaringan, dan panjang lintasan rata-rata (*average path length*).

Tabel 2. 1 Properti Jaringan

Propoerti Jaringan	Penjelasan
<i>Nodes</i>	<i>nodes</i> menggambarkan posisi atau peran yang dimiliki oleh setiap aktor dalam suatu jaringan,
<i>Edges</i>	Merepresentasikan hubungan atau interaksi yang terbentuk antar aktor dalam jaringan tersebut.
<i>Average Degree</i>	Dihitung dengan membagi jumlah koneksi pada suatu node dengan total hubungan dalam keseluruhan jaringan sosial.
<i>Diameter</i>	Mengacu pada jarak terpanjang antara dua simpul yang saling terhubung dalam jaringan.
<i>Average Path Length</i>	Rata-rata panjang lintasan terpendek yang menghubungkan setiap pasangan node dalam jaringan tersebut.

2.1.2.2 *Centrality* pada *Social Network Analysis*

Centrality digunakan sebagai ukuran untuk mengidentifikasi elemen yang memiliki peran paling signifikan dalam suatu jaringan sosial, yang mencerminkan tingkat kepentingan atau posisi sentral seorang aktor dalam jaringan tersebut (Mincer & Niewiadomska-Szynkiewicz, 2012 dalam Brastawisnu 2018). Terdapat

empat jenis utama pengukuran *centrality*, yaitu: *degree centrality*, *betweenness centrality*, *closeness centrality*, dan *eigenvector centrality*.

Tabel 2. 2 Pengertian *Centrality*

Penjelasan
Menurut Alhaji dan Rokne (2014), <i>degree centrality</i> dihitung berdasarkan banyaknya hubungan (edges) yang dimiliki oleh suatu simpul (node) dalam jaringan.
<i>Betweenness centrality</i> , sebagaimana dijelaskan oleh Mbaru dan Barnes (2017), digunakan untuk mengidentifikasi simpul yang berfungsi sebagai penghubung atau perantara dalam aliran informasi antar simpul lainnya.
<i>Closeness centrality</i> menggambarkan seberapa dekat suatu simpul dengan seluruh simpul lainnya dalam jaringan, yang dihitung melalui rata-rata jarak terpendek antar node (Alhaji dan Rokne, 2014).
Sementara itu, <i>eigenvector centrality</i> menilai pentingnya sebuah simpul berdasarkan kualitas koneksi yang dimilikinya, termasuk koneksi terhadap simpul-simpul yang juga berpengaruh (Alhaji dan Rokne, 2014).

Dalam era digital saat ini, pertumbuhan pesat jejaring sosial dan interaksi antar individu melalui *platform online* telah menghasilkan jumlah data yang luar biasa. Data ini tidak hanya mencakup informasi tentang hubungan antar orang, tetapi juga mengandung pola-pola kompleks yang dapat memberikan wawasan mendalam tentang struktur dan dinamika masyarakat. Salah satu pendekatan yang kuat untuk menganalisis struktur sosial dan hubungan di antara entitas-entitas adalah melalui *Social Network Analysis (SNA)* memanfaatkan pendekatan teori graf untuk merepresentasikan serta mengevaluasi hubungan antara individu atau entitas dalam suatu struktur sistem tertentu.

2.1.3 *Graph Network Analysis*

Graph Theory adalah cabang matematika yang mempelajari hubungan antar objek melalui representasi *graf*. *Graf*, yang terdiri dari simpul (*node*) dan tepi

(*edge*), dapat merepresentasikan berbagai jenis hubungan, termasuk hubungan sosial dalam jaringan *online*.

2.1.3.1 Graf atau Graph

Graf adalah struktur matematis yang terdiri dari simpul-simpul (*nodes*) yang terhubung oleh tepi (*edges*). Dalam graf, simpul mewakili entitas atau titik, sedangkan tepi merepresentasikan hubungan antar-simpul. *Graf* digunakan untuk memodelkan berbagai jenis hubungan dan struktur, dan merupakan alat yang penting dalam matematika diskrit, ilmu komputer, dan berbagai bidang lainnya.

Graf dilambangkan dengan persamaan berikut: $G = (V, E)$

V adalah sekumpulan simpul (*vertices*) yang bersifat tidak kosong dalam suatu struktur graf.

$$V = \{v_1, v_2, \dots, v_n\}.$$

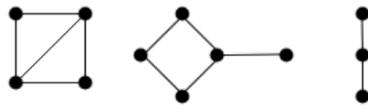
E merupakan kumpulan sisi (*edges*) yang berfungsi menghubungkan dua buah simpul (*nodes*) dalam suatu graf.

$$E = \{e_1, e_2, \dots, e_n\}.$$

2.1.3.2 Jenis-Jenis Graf atau Graph

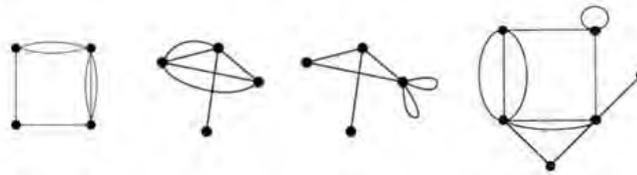
Graf terdiri dari berbagai jenis, salah satunya adalah graf berarah dan graf tak berarah. Pada graf berarah, setiap sisi memiliki arah tertentu, yang menunjukkan bahwa hubungan antar simpul bersifat searah atau memiliki orientasi khusus. Sementara itu, pada graf tak berarah, sisi-sisinya tidak memiliki arah tertentu, sehingga hubungan antar simpul bersifat timbal balik. Selain itu, graf juga dapat diklasifikasikan menjadi graf berbobot, yang memiliki nilai pada setiap sisi, dan graf tak berbobot, yang tidak menyertakan nilai bobot pada hubungan antar simpul. *Graf* berbobot memiliki nilai atau bobot yang terkait dengan setiap tepi, yang mencerminkan karakteristik atau atribut dari hubungan tersebut. Berdasarkan jenis sisi (*ganda* atau *gelang*), *graf* digolongkan menjadi dua jenis:

- a) **Graf sederhana (*simple graph*)** adalah jenis graf yang tidak memiliki sisi ganda maupun gelang (*loop*), sehingga setiap pasangan simpul hanya dihubungkan oleh satu sisi dan tidak terdapat sisi yang menghubungkan simpul dengan dirinya sendiri.



Gambar 2. 1 Graf Sederhana

- b) **Graf tak-sederhana (*unsimple graph*)** merupakan graf yang memiliki sisi ganda atau gelang, yaitu adanya lebih dari satu sisi yang menghubungkan pasangan simpul yang sama, atau sisi yang menghubungkan simpul dengan dirinya sendiri.



Gambar 2. 2 Graf tak sederhana

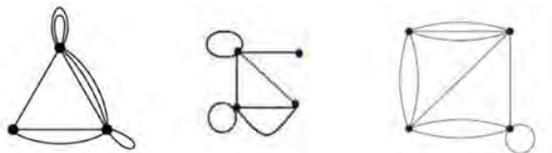
Graf tak-sederhana diklasifikasikan lebih lanjut menjadi dua tipe, yaitu:

- a) **Graf ganda (*multigraf*)**, yakni graf yang memiliki lebih dari satu sisi yang menghubungkan pasangan simpul yang sama.



Gambar 2. 3 Graf Ganda

- b) **Graf semu (*pseudo-graph*)** adalah jenis graf yang memiliki sisi gelang, yaitu sisi yang menghubungkan suatu simpul dengan dirinya sendiri.



Gambar 2. 4 Graf Semu

2.1.4 Naïve Bayes Classifier

Algoritma Naïve Bayes Classifier merupakan algoritma yang mengimplementasikan teorema Naïve Bayes Classifier. Teorema Bayes membahas

tentang kemungkinan munculnya atau terjadinya suatu fakta pada beberapa peristiwa yang terjadi. Teorema Bayes digunakan untuk memprediksi fakta dengan menggunakan fakta yang telah terjadi sebelumnya. (Ranganathan dkk., 2018)

Naïve Bayes *Classifier* merupakan salah satu algoritma yang banyak digunakan dalam proses *data mining* karena kemudahan penerapannya serta kecepatan dalam pemrosesan data (Hall, 2007 dalam Faturrohman 2023). Struktur algoritma ini tergolong sederhana namun tetap menunjukkan kinerja yang efektif (Taheri & Mammadov, 2013 dalam Faturrohman 2023). Secara prinsip, algoritma ini mengasumsikan bahwa keberadaan suatu fitur dalam suatu kelas tidak dipengaruhi oleh fitur lainnya. Sebagai ilustrasi, objek yang berwarna merah, berbentuk bulat, dan memiliki diameter sekitar 10 cm dapat dikenali sebagai apel. Meskipun dalam kenyataannya fitur-fitur tersebut saling berkaitan, Naïve Bayes tetap memperlakukan setiap fitur secara independen. (Sujadi, 2022). Naïve Bayes *Classifier* banyak digunakan untuk mengklasifikasikan informasi atau data. Karena tidak ada saling ketergantungan antar fitur data yang diolah, maka dianggap naive. Dalam pengelompokannya, Naïve Bayes *Classifier* memerlukan data latih yang dapat menjawab seluruh informasi agar dapat memperoleh prediksi secara tepat. Prediksi yang dibuat dengan menggunakan algoritma Naïve Bayes *Classifier* berdasarkan teorema bayes umumnya berbentuk sebagai berikut:

$$P(c|d) = \frac{P(c)P(d|c)}{P(d)}$$

Berikut penjelasannya,

d : mewakili dokumen yang belum ditentukan kelasnya

c : merupakan simbol yang menunjukkan kelas tertentu, seperti kelas positif atau negatif

$P(c/d)$: probabilitas bahwa dokumen d termasuk ke dalam kelas c

$P(c)$: probabilitas terjadinya kelas c secara umum

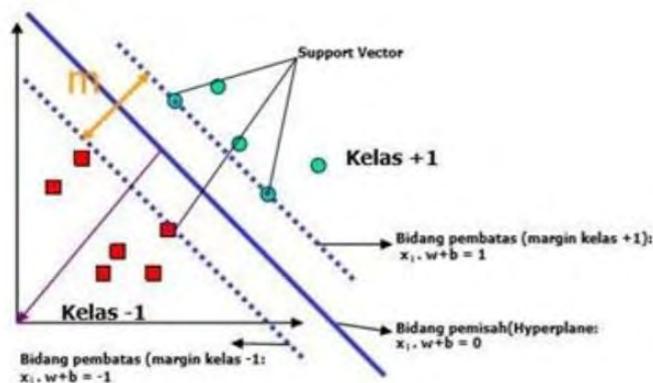
$P(d/c)$: probabilitas dokumen d muncul jika diketahui berada dalam kelas c

Selain menganalisis sentimen dan topik yang sedang berkembang, penting juga untuk memahami pola penyebaran opini dalam jaringan media sosial. Analisis Jaringan Grafik (*Graph Network Analysis*) digunakan untuk memetakan sumber yang data yang berpengaruh dan menggunakan kalimat maupun sebaran kata yang

sering muncul dan digunakan dalam topik bahasan putusan Mahkamah Konstitusi No. 60/PUU-XXII/2024.

2.1.5 Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan salah satu algoritma pembelajaran mesin yang cukup populer, terutama dalam penyelesaian permasalahan klasifikasi dan regresi. *SVM* termasuk dalam kategori algoritma *supervised learning* yang mampu menangani data dengan pola linier maupun non-linier. Konsep utama dari *SVM* adalah mencari *hyperplane* pada ruang berdimensi tinggi yang dapat memisahkan antar kelas dengan margin sejauh mungkin. Artinya, *SVM* bertujuan untuk menentukan batas keputusan (*decision boundary*) terbaik yang mampu mengklasifikasikan data secara akurat, sekaligus menjaga jarak maksimal dari titik data terdekat di masing-masing kelas. Untuk mencapai hal tersebut, *SVM* memanfaatkan teknik *kernel trick*—yaitu metode untuk memetakan data ke ruang fitur berdimensi lebih tinggi, di mana pemisahan antar kelas menjadi lebih mudah dilakukan. Beberapa jenis kernel yang sering digunakan dalam *SVM* antara lain kernel linier, polinomial, dan fungsi basis radial (RBF). Tujuan utama algoritma ini adalah memperoleh fungsi klasifikasi yang optimal, agar dapat meminimalkan kemungkinan kesalahan dalam membedakan data dari dua kelas yang berbeda. Pada data yang dapat dipisahkan secara linier, fungsi klasifikasi ini diwujudkan melalui *hyperplane* yang terletak tepat di antara dua kelas tersebut, berfungsi sebagai batas pemisah secara geometris. (Gigih, 2024)



Gambar 2. 5 Margin Hyperplane

Support Vector Machine (SVM) merupakan metode yang digunakan dalam proses klasifikasi maupun regresi. Terdapat berbagai varian dari algoritma *SVM*, namun yang paling umum digunakan adalah *SVM* dengan pendekatan fungsi kernel. Secara umum, formulasi dasar *SVM* untuk tugas klasifikasi dapat dinyatakan melalui persamaan berikut:

$$K(X_1, X_j) = \tanh(ax_1 + X_j + \beta)$$

Keterangan:

K : Kernel

X & Y : *Vector input space*

d : *quadratic*

α : *scalar parameter*

2.2 Teori Pendukung

Dalam penelitian ini, penulis menerapkan pendekatan *machine learning* yang digunakan untuk melatih model dalam mengklasifikasikan sentimen menjadi tiga kategori, yaitu positif, negatif, dan netral. Pendekatan **lexicon-based** dipilih karena sifatnya yang sederhana, praktis, dan relevan untuk menganalisis sentimen pada data dari media sosial (Matulatuwa et al., 2017). Pendekatan ini berasumsi bahwa orientasi sentimen dalam suatu konteks dapat ditentukan dari jaringan makna kata atau frasa yang digunakan. *Lexicon* digunakan untuk mengekstraksi sentimen dengan cara menggabungkan pengetahuan leksikal dan teknik klasifikasi teks.

Menurut Hu et al. (2004), yang dikutip dalam Liu (2012) dalam Afifi (2022), algoritma berbasis *lexicon* dapat digunakan untuk menentukan orientasi sentimen berdasarkan aspek-aspek tertentu. Penentuan orientasi ini dilakukan dengan menjumlahkan nilai sentimen dari setiap kata dalam kalimat, di mana kata-kata bernilai positif diberi skor +1 dan kata-kata negatif diberi skor -1. Selain itu, kata-kata yang mengandung unsur negasi seperti “namun” atau “tetapi” juga turut diperhitungkan dalam penentuan makna keseluruhan.

2.2.1 Algoritma *Machine Learning*

Algoritma Pembelajaran Mesin atau *Machine Learning Algorithm* adalah serangkaian metode dan teknik yang digunakan dalam pembelajaran mesin untuk mengambil informasi atau pola tersembunyi dari data dan membuat prediksi atau keputusan tanpa secara eksplisit diprogram secara manual. Algoritma ini memungkinkan mesin atau komputer untuk belajar dari data yang diberikan dan meningkatkan kinerjanya seiring bertambahnya pengalaman. Algoritma pembelajaran mesin memiliki kemampuan untuk mengatasi kompleksitas dan pola yang rumit dalam data, kemampuan adaptasi terhadap perubahan, dan kemampuan untuk membuat prediksi atau keputusan berdasarkan data yang baru. Algoritma pembelajaran mesin digunakan dalam berbagai aplikasi seperti pengenalan wajah, analisis data, dan pengolahan bahasa alami dan banyak lainnya. Pada dasarnya, algoritma pembelajaran mesin dapat dikelompokkan ke dalam tiga kategori utama, *supervised Learning* (Pembelajaran terarah), *unsupervised Learning* (Pembelajaran Tanpa Pengawasan), dan *Reinforcement Learning* (Pembelajaran Penguatan) (Burrel. J. 2026). Berikut Penjelasan singkat untuk setiap kategori:

- a) ***Supervised Learning***, algoritma pembelajaran mesin yang mempelajari pola atau hubungan antara input dan output yang terkait. Data pelatihan yang digunakan dalam *supervised learning* memiliki pasangan input dan output yang sudah diketahui. Algoritma ini belajar untuk membuat prediksi atau klasifikasi berdasarkan pola yang ada dalam data pelatihan. Contoh algoritma *supervised learning* adalah regresi linear, *Naïve Bayes Classifier*, *Support Vector Machines* (SVM), dan *Random Forest*;
- b) ***Unsupervised Learning***, algoritma pembelajaran mesin dalam kategori ini digunakan ketika tidak ada label atau output yang diketahui dalam data. Tujuan dari *unsupervised learning* adalah untuk mengidentifikasi pola atau struktur tersembunyi dalam data. Algoritma ini melakukan pengelompokan (*clustering*) data berdasarkan kesamaan fitur atau mengurangi dimensi data. contoh algoritma *unsupervised learning* termasuk *K-means clustering*, *Principal Component Analysis* (PCA), dan *Association Rule Learning*;
- c) ***Reinforcement Learning***, algoritma pembelajaran mesin dalam kategori ini berinteraksi dengan lingkungan dan mempelajari tindakan apa yang harus

diambil berdasarkan umpan balik atau reward yang diberikan oleh longkungan. Algoritma *reinforcement learning* memaksimalkan *reward* dalam situasi tertentu melalui proses *trial-and-error*. Contoh algoritma *reinforcement learning* adalah *Q-Learning* dan *Deep Q-Network (DQN)*.

2.3 Penelitian Terdahulu

Dalam rangka mendukung dan menjadi sumber acuan dalam penelitian kalini, berikut adalah list dari jurnal yang digunakan penulis untuk dasar referensi pada penelitian ini.

Tabel 2. 3 Penelitian Terkait

No	Penulis,Tahun, Penerbit	Judul	Metode	Hasil
1.	Ritma Melati, M. Reza Redo Islami, 2024, Jurnal TAM (Technology Acceptance Model)	Analisis Sentimen Data Twitter Menggunakan Metode K-Means Clustering Pada Studi Kasus Pemindahan Ibu Kota Nusantara (IKN)	K-Means	Dari hasil analisis sentimen dan clustering menggunakan metode k-means clustering di atas bahwa hasil tertinggi sebanyak 79,31% dengan tanggapan masyarakat mengenai pemindahan ibu kota nusantara atau IKN yaitu secara negatif dan yang beranggapan netral sebanyak 20,69%. Dan hasil tertinggi dari <i>clustering</i> menggunakan metode k-means clustering yaitu cendroid 2 atau C2 hasil dari tabel violin plot sebesar 0.68.
2.	Syafreza Fachlevi, Andi Alimuddin Unde, Hasrullah, 2024, Jurnal Syntax Admiration	Analisis Sentemen Publik pada Tagar #KawalPutusanM K di Media Sosial X	Kualitatif Deskriptif	Secara umum, data dari tagar #KawalPutusanMK memiliki dampak jangka panjang yang signifikan. Dominasi sentimen negatif mencerminkan adanya ketidakpuasan publik terhadap lembaga negara, yang dapat mendorong munculnya lebih banyak diskusi maupun gerakan sosial di kemudian hari. Dalam konteks big data, hal ini menjadi peringatan bagi pemerintah dan pembuat kebijakan untuk tidak sekadar memantau opini publik, tetapi juga menelaah pola yang berkembang dan meresponsnya secara cepat sebelum isu tersebut berkembang menjadi krisis yang lebih kompleks.
3.	Aulia Alqusyiah Fitri, Andreas Perdana, 2024,	Analisis Senimen Publik terhadap Keputusan MK mengenai Batasan usia kandidat	<i>Vader</i> (<i>Valence</i> <i>Aware</i> <i>Dictionary</i> <i>and</i>	Setelah dilakukan visualisasi terhadap 2621 <i>tweets</i> , hasil presentase yang diperoleh yaitu sebesar 90.35% untuk hasil presentase sentiment netral, 6.02% untuk hasil presentasi

	Jurnal TAM (Technology Acceptance Model)	CAPRES dan CAWAPRES berdasarkan Media Sosial Twitter menggunakan Metode VADER	<i>Sentiment Reasoner</i>	sentiment negatif, dan 3.63% untuk hasil presentasi sentiment positif. Hasil analisis menunjukkan mayoritas public cenderung merespons keputusan tersebut secara netral. Dalam konteks ini, metode VADER (<i>Valence Aware Dictionary and Sentiment Reasoner</i>) dapat memberikan gambaran cukup akurat terkait <i>sentiment public</i> terhadap keputusan MK mengenai batas usia capres dan cawapres.
4.	Yenny Heriyanti, Slamet Kacung, Budi Santoso, 2024, <i>Multidisiplinary Indonesian Center Journal (MICJO)</i>	Analisis Sentimen Terhadap Putusan Mahkamah Konstitusi Tentang Batasan Umur Capres Dan Cawapres Menggunakan Metode Naïve Bayes Classifier	Naïve Bayes Classifier	Penelitian ini menggunakan algoritma Naïve Bayes Classifier untuk melakukan analisis sentimen terhadap data dari Twitter, dengan tujuan mengidentifikasi persepsi publik terhadap regulasi yang dimaksud. Hasil analisis mengungkap bahwa mayoritas unggahan bersentimen negatif (90,9%), sementara sentimen positif hanya mencakup 6,6% dan netral sebesar 2,5%. Temuan ini menunjukkan adanya ketidakpuasan yang cukup kuat di kalangan masyarakat. Tingkat akurasi model dalam mengklasifikasikan sentimen mencapai 67,98%, yang membuktikan bahwa algoritma Naïve Bayes efektif digunakan dalam konteks ini. Penelitian ini menekankan pentingnya diskusi lebih lanjut mengenai kriteria pencalonan yang mampu mencerminkan aspirasi masyarakat, termasuk mempertimbangkan aspek pengalaman dan kematangan calon.
5.	Rosit Sanusi, Femi Dwi Astuti, Indra Yatini Buryadi, 2021, <i>JIKO (Jurnal Informatika dan Komputer)</i>	Analisis Sentimen Pada Twitter Terhadap Program Kartu Pra Kerja Dengan <i>Recurrent Neural Network</i>	RNN	Dari hasil pembahasan sebelumnya, dapat disimpulkan bahwa data sampel yang digunakan tergolong tidak seimbang. Dari total 4.122 data, sebanyak 2.460 di antaranya berlabel netral, 689 berlabel positif, dan 973 berlabel negatif. Proses pelatihan menghasilkan akurasi sebesar 95,66% dengan nilai loss sebesar 0,1999 setelah menjalani 36 <i>epoch</i> . Namun, hasil pengujian model masih belum optimal, dengan akurasi hanya mencapai 64,48% dan nilai loss sebesar 1,5922. Berdasarkan perbandingan hasil pelatihan dan pengujian, dapat disimpulkan bahwa model mengalami gejala <i>overfitting</i> .
6.	Alif Faturrohman, Tommy Gunawan, Aryatama	Analisis Sentimen Pembacaan Putusan Mk Terkait Pilpres 2024 Pada	Naïve Bayes Classifier	Berdasarkan hasil evaluasi performa model yang telah peneliti lakukan, dapat disimpulkan bahwa model Naïve Bayes Classifier yang digunakan dalam proses <i>data mining</i>

	Attariq H Putra, Nur Aini Rakhmawati, 2023,	Aplikasi X Dengan Metode Naïve Bayes Classifier		ini mampu mengklasifikasikan data dengan baik, baik pada kategori "Negative" maupun "Positive". Tingkat akurasi yang tinggi dan keseimbangan yang baik antara presisi, <i>recall</i> , dan <i>f1-score</i> menunjukkan bahwa model ini dapat diandalkan untuk tugas-tugas klasifikasi yang serupa. Dengan demikian, model ini layak untuk digunakan dalam aplikasi praktis yang membutuhkan analisis dan klasifikasi data secara akurat.
7.	Artia Irianti, Halimah, Melda Agariana, 2024, Jurnal Teknik Informatika (JUTIF)	<i>Integration of BERT and SVM in Sentiment Analysis of Twitter Regarding Constitutional Court Decision /X Regarding Constitutional Court Decision No. 60/PUU-XXII/2024</i>	BERT dan SVM	Dari hasil distribusi sentimen, terlihat adanya dominasi sentimen positif, dengan netral dan negatif yang jauh lebih sedikit. Ini karena data yang digunakan memang cenderung mengarah pada sentimen positif. Model BERT sendiri memang lebih cenderung memberi label positif pada teks yang ambigu. Sentimen positif lebih padat dalam area tertentu, sementara negatif dan netral menunjukkan distribusi yang lebih menyebar. Akurasi tinggi yang ditunjukkan oleh model dipengaruhi oleh jumlah besar data positif. Model menghasilkan kinerja yang baik untuk kelas positif, kinerja pada kelas negatif masih perlu diperbaiki. Performa yang kurang optimal pada kelas negatif dan netral mengindikasikan bahwa model mengalami ketidakseimbangan kelas. Model lebih fokus pada deteksi kelas mayoritas (positif), sehingga lebih sulit untuk mengenali sentimen negatif dan netral. Integrasi BERT Dan SVM dalam analisis sentimen berhasil dan dapat dilakukan, terlihat juga model ini mampu menangkap nuansa sentimen dengan baik.
8.	Iin, Reza Supriatna, Mulyawan, Dede Rohmah, 2024, JATI (Jurnal Mahasiswa Teknik Informatika)	Penerapan <i>Natural Language Processing</i> Dalam Analisis Sentimen Cawapres 2024 Menggunakan Algoritma Naïve Bayes Classifier	Naïve Bayes Classifier	Berbagai hasil analisis sentimen di <i>platform</i> Twitter menunjukkan bahwa teks yang diungkapkan oleh masyarakat dapat bersifat negatif, positif, maupun netral. Dalam penelitian ini, perhatian utama diarahkan pada penilaian jenis sentimen yang terkandung dalam teks tersebut. Metode yang digunakan adalah pendekatan SEMMA (<i>sample, explore, modify, assess</i>), dengan algoritma Naïve Bayes Classifier sebagai alat klasifikasinya. Prediksi sentimen dianalisis menggunakan <i>confusion matrix</i> untuk memperoleh

			metrik evaluasi berupa presisi, akurasi, dan <i>recall</i> . Berdasarkan hasil evaluasi, model Naïve Bayes menghasilkan nilai <i>recall</i> sebesar 73,98%, akurasi 77,37%, serta presisi mencapai 100%..
9.	Agung Wijoyo, Asep Yudistira, Safitri Ristanti, DKK, 2024, OKTAL: Jurnal Ilmu Komputer dan Science	Pembelajaran <i>Machine Learning</i>	Pembahasan mengenai konsep dasar <i>Machine Learning</i> dan <i>Artificial Intelligence</i> , (2) Pengenalan pemrograman Python sebagai fondasi dalam pengembangan <i>Machine Learning</i> , serta (3) Implementasi praktis <i>Machine Learning</i> menggunakan Python melalui berbagai algoritma baik dalam kategori <i>Supervised</i> maupun <i>Unsupervised Learning</i> . Sejumlah studi kasus disajikan secara menyeluruh, mencakup pemahaman algoritma, pengolahan data, proses pelatihan dan pengujian model, hingga visualisasi hasil dari model <i>Machine Learning</i> yang dibangun.
10.	Abdullah Mubarak, 2023, Makalah IF2120 Matematika Diskrit	Analisis Sosial dengan Menggunakan Graf dan NetworkX	<i>Social Network Analysis</i> (SNA) adalah ilmu yang mempelajari cara mendapatkan informasi berharga dari suatu jaringan sosial yang digambarkan sebagai graf dengan simpul adalah individu/ <i>actor</i> dan sisi sebagai hubungan antar simpul. Pada SNA, terdapat metrik-metrik yang penting untuk diperhitungkan dalam mengambil kesimpulan dari suatu jaringan sosial, salah satunya adalah sentralitas. Sentralitas suatu <i>node</i> menggambarkan seberapa pengaruh <i>node</i> tersebut dalam suatu graf. Terdapat banyak cara perhitungan sentralitas, penulis hanya mengambil tiga : <i>point centrality</i> , <i>betweenness centrality</i> , dan <i>closeness centrality</i> .
11.	Yesy Simanjuntak, Peter Tymothy Hutabarat, Rani Indah Sari Manurung, Putri Harliana, 2025, Jurnal PROSISKO	Analisis Jaringan Sosial Sederhana Menggunakan Algoritma Graf	Penelitian ini mengadopsi pendekatan kualitatif yang bertujuan untuk menggambarkan bagaimana media digunakan dalam konteks interaksi sosial yang lebih luas, serta bagaimana hal tersebut memengaruhi perilaku sosial masyarakat. Interaksi ini kemudian divisualisasikan dalam bentuk model graf. Temuan penelitian menunjukkan bahwa simpul-simpul (<i>nodes</i>) dengan tingkat <i>centrality</i> tinggi memiliki peran penting sebagai penghubung utama dalam aliran informasi dan pembentukan opini publik. Selain itu, teridentifikasi pula keberadaan sub-komunitas dalam jaringan yang secara nyata

				memengaruhi dinamika sosial di dalamnya..
12.	Tifani Intan Solihati, Raden Kania, Rudianto, 2023, Jurnal Teknik Informatika dan Sistem Informasi	Analisis Tren dan Pemetaan Penelitian Mahasiswa Teknik Informatika Menggunakan <i>Graph Convolutional Network</i>	<i>Graph Convolutional Network</i>	Penelitian ini terdiri dari beberapa tahapan utama. Tahap pertama adalah <i>preprocessing</i> , di mana peneliti melakukan pengumpulan data skripsi mahasiswa dari Program Studi Teknik Informatika. Selanjutnya, pada tahap <i>learning algorithm</i> , data yang telah terstruktur digunakan sebagai <i>data training</i> untuk dilatih menggunakan algoritma <i>Graph Convolutional Network (GCN)</i> hingga menghasilkan <i>candidate model</i> , kemudian dipilih dan diterapkan sebagai <i>selected model</i> . Tahap berikutnya adalah <i>application</i> , yakni penerapan <i>golden model</i> terhadap <i>data testing</i> yang telah disiapkan sebelumnya, untuk kemudian dilakukan pengukuran akurasi model tersebut. Berdasarkan hasil penelitian, diketahui bahwa tren topik skripsi mahasiswa Teknik Informatika cenderung lebih banyak berada dalam ranah keilmuan matematika dan statistika, serta arsitektur komputer, dengan jumlah masing-masing sebanyak 182 dan 101 judul. Akurasi model GCN dalam menentukan kelas target mencapai 68,25%.
13.	Budi Susanto, Herlina, Antonius R.C, <i>Graph Social Network Analysis</i>	Penerapan <i>Social Network Analysis</i> dalam Penentuan <i>Centrality</i> Studi Kasus <i>Social Network Twitter</i>		Metode <i>betweenness centrality</i> digunakan untuk mengidentifikasi akun Twitter yang berperan sebagai penghubung utama dalam suatu jaringan, yaitu akun yang memiliki potensi tinggi untuk menjembatani koneksi antar kelompok atau pasangan <i>node</i> . Sementara itu, <i>closeness centrality</i> dimanfaatkan untuk mengetahui akun mana yang memiliki akses tercepat dan paling luas terhadap seluruh simpul dalam jaringan, menunjukkan tingkat visibilitas yang tinggi. Untuk meningkatkan akurasi analisis, pengembangan aplikasi perlu diarahkan agar tidak lagi dibatasi oleh kuota permintaan (<i>request</i>) dari API Twitter. Dengan akses yang tidak terbatas, sistem dapat menghitung nilai <i>centrality</i> secara lebih akurat karena mempertimbangkan keseluruhan <i>node</i> dalam jaringan. Selain itu, akurasi perhitungan juga dapat ditingkatkan dengan menambahkan variabel lain, seperti penggunaan <i>hashtag</i> , <i>mention</i> ,

				maupun <i>retweet</i> , bukan hanya berdasarkan hubungan pertemanan saja.
14.	Made Kevin Bratawisnu, Andry Alamsyah, 2018, Jurnal Manajemen dan Bisnis (ALMANA)	<i>Sosial Network Analysis untuk Analisa Interaksi User dimedia sosial mengenai Bisnis E-Commerce</i>	<i>Social Network Analysis</i>	Salah satu <i>platform</i> yang dapat dimanfaatkan dalam pengumpulan informasi adalah media sosial. Di dalamnya tersedia berbagai jenis konten, termasuk konten yang dibuat langsung oleh pengguna atau dikenal sebagai <i>User Generated Content (UGC)</i> . <i>UGC</i> merupakan rekam jejak aktivitas pengguna yang dapat diakses oleh pengguna lain. Untuk memahami pola interaksi antara perusahaan dan konsumen melalui <i>UGC</i> yang tersebar luas dimedia sosial, dibutuhkan analisis media sosial. Informasi yang diperoleh dari analisis ini dapat menjadi masukan berharga bagi perusahaan dalam merancang strategi pemasaran digital. Salah satu metode yang digunakan untuk menganalisis pola tersebut adalah <i>Social Network Analysis (SNA)</i> . Melalui pemodelan jaringan sosial, bisnis e-commerce dapat memperoleh pemahaman yang lebih baik tentang dinamika interaksi yang berlangsung di media sosial.
15.	Gigih Nur Hendrawan, Harni kurniyanti, 2024, CESS	<i>Evaluasi Performa Naive Bayes dan SVM dalam Analisis Sentimen Kendaraan Listrik di Media Sosial Twitter</i>	Naïve Bayes	Hasil evaluasi perbandingan antara algoritma <i>Support Vector Machine (SVM)</i> dan Naive Bayes dalam klasifikasi sentimen pada data Twitter menunjukkan bahwa <i>SVM</i> memiliki keunggulan yang signifikan dengan tingkat akurasi mencapai 95,79%, mengungguli Naive Bayes yang mencatat akurasi sebesar 87,39%. <i>SVM</i> terbukti lebih andal dalam mengidentifikasi sentimen positif dan negatif secara tepat. Sebaliknya, Naive Bayes menunjukkan kecenderungan lebih tinggi dalam melakukan kesalahan klasifikasi. Meskipun performa <i>SVM</i> tergolong menjanjikan, masih terdapat kekhawatiran terkait potensi <i>overfitting</i> pada model tersebut.
16.	Achmad Bayhaqy, Kaman Nainggolan, Sfenrianti Emil Kaburuan, 2018 Researchgate.	<i>Sentiment Analysis about E-Commerce from Tweets Using Decision Tree, K-Nearest Neighbor, and Naïve Bayes</i>	Naïve Bayes	Penelitian ini membandingkan analisis sentimen pada <i>tweet</i> tentang Tokopedia dan Bukalapak menggunakan teknik data mining. Proses meliputi tokenisasi, stemming, dan klasifikasi dengan bantuan Rapid Miner. Tiga metode digunakan: Decision Tree, K-NN, dan Naïve Bayes. Hasil terbaik diperoleh dari Naïve Bayes dengan akurasi 77%, precision 88,5%, dan recall 64%.

17.	Emil R. Kaburuan, Yinita Sartika Sari, Ika Agustina, 2022, Lomtar Komputer	<i>Sentiment Analisis on Product Reviews from Shopee Marketplace using the naive bayes classiffier</i>	Naïve Bayes	Penelitian ini menganalisis ulasan produk pakaian rumah wanita di Shopee dengan klasifikasi sentimen positif dan negatif. Proses mencakup <i>crawling</i> data, <i>preprocessing</i> teks, pelatihan dan pengujian model. Algoritma Naïve Bayes digunakan untuk klasifikasi dengan akurasi 90,03%, dari total 2.907 data ulasan.
-----	--	--	-------------	--

2.4 Gap Penelitain

Pemilihan judul Analisis Sentimen dan *Graph Network*: Reaksi Publik Terhadap Putusan Mahkamah Konstitusi No. 60/PUU-XXII/2024 adalah salah satu respon ide dari penulis untuk menanggapi gejolak pada saat putusan cukup ramai diperbincangkan oleh netizen di media sosial. Dalam model gagasan ini belum ditemukan jurnal yang menganalisis sentimen dengan kolaborasi mengkaji *graph network* saat mengulas berita yang sedang ramai. Kali ini penulis juga ingin mengukur kemampuan mengolah data dengan memanfaatkan *machine learning* dengan metode Naïve Bayes *Classifier* sebagai pilihan algoritma yang dijadikan motor dalam mengolah data sesuai dengan kriteria yang telah ditentukan. Harapannya dengan ide penelitian ini bisa menambah variasi tema penelitian analisis sentimen yang dikolaborasikan dengan *graph network*.

UNIVERSITAS
MERCU BUANA