

GABUNGAN TEKNIK PENGEKSTRAKAN FITUR TF-IDF DENGAN PEMBELAJARAN ENSEMBEL VOTING UNTUK PENGESANAN BERITA PALSU

Zakiah Hanum bt Hj Hashim @ Hj Abu Bakar, Nor Samsiah bt Sani

Fakulti Teknologi dan Sains Maklumat, Universiti Kebangsaan Malaysia
43600 UKM Bangi, Selangor Malaysia.

zahanum.ukm@gmail.com, norsamsiahsani@ukm.edu.my

ABSTRAK

Perkembangan teknologi dan perubahan cara penggunaan maklumat daripada tradisional kepada digital telah menyebabkan peningkatan penyebaran berita palsu secara mendadak. Ianya menyukarkan pencarian dan pengurusan maklumat serta semakan manual tidak lagi relevan dan praktikal. Berita palsu adalah sejenis pendapat umum untuk menipu bagi mencapai tujuan tertentu yang memberi kesan negatif terhadap penerimaan dan penggunaan maklumat tersebut. Banyak kajian dalam mengesan berita palsu telah dilakukan menggunakan set data sedia ada dan kebanyakannya telah mencapai prestasi optimum. Namun, dalam pengelasan teks, terdapat dua (2) faktor yang mempengaruhi prestasi model iaitu teknik pengekstrakan fitur dan penggunaan model pembelajaran mesin. Pengekstrakan fitur adalah proses menukar teks kepada numerik. Pembelajaran ensemble digunakan secara meluas dan dapatan kajian lepas mendapati prestasi model melebihi prestasi pengelas individu. Oleh itu, kajian ini mencadangkan teknik pengekstrakan fitur TF-IDF dengan pembelajaran ensemble Voting (TifVot) untuk mengesan berita palsu menggunakan data berita palsu yang baru dari Kaggle iaitu fake news classifiers (kfnc). Objektif kajian ini adalah untuk mengenal pasti kaedah pengekstrakan fitur dan model pembelajaran ensemble yang terbaik untuk mengklasifikasi dan mengesan berita palsu. Tiga (3) teknik pengekstrakan fitur iaitu TF-IDF, CountVectorizer dan N-gram (bigram dan trigram) diuji bersama tiga (3) model pembelajaran ensemble iaitu Hutan Rawak (RF), XGBoost dan Voting. Proses penalaan hiperparameter model dilakukan bagi mengenal pasti nilai hiperparameter yang optimum untuk meningkatkan prestasi model. Seterusnya, prestasi model dinilai dan dibandingkan untuk menentukan model pembelajaran ensemble terbaik. Keputusan menunjukkan TF-IDF merupakan teknik pengekstrakan fitur terbaik dan Voting merupakan model pembelajaran ensemble terbaik berdasarkan skor purata tertinggi iaitu 0.970 dan meningkat kepada 0.974 setelah proses penalaan hiperparameter dilakukan. Ujian statistik turut menunjukkan perbezaan prestasi TifVot dengan model lain adalah signifikan secara statistik ($p < 0.05$). Pendekatan Explainable Artificial Intelligence (xAI) - LIME digunakan untuk mentafsir ramalan model pengesanan berita palsu bagi meningkatkan kefahaman dapatan kajian. Oleh itu, gabungan teknik pengekstrakan fitur TF-IDF dan pembelajaran ensemble Voting merupakan teknik terbaik dalam mengesan berita palsu.

Keyword: Berita Palsu, TF-IDF, CountVectorizer, N-gram, Pembelajaran Ensemble, Hutan Rawak, XGBoost, Voting, LIME

1. PENGENALAN

Berita palsu adalah sejenis pendapat umum untuk menipu bagi mencapai tujuan tertentu yang memberi kesan negatif terhadap penerimaan dan penggunaan maklumat tersebut (Li 2021).

Perkembangan teknologi dan perubahan cara penggunaan maklumat daripada tradisional kepada digital telah menyebabkan peningkatan penyebaran berita palsu secara mendadak (Coste & Bufnea 2021). Bagi membendung masalah ini, terdapat beberapa laman web dibangunkan untuk menyemak kesahihan sesuatu maklumat atau berita seperti snopes.com, factcheck.org, fakenewswatch.com, politifact.com dan lain-lain (Alameri & Mohd 2021; Shaikh & Patil 2020). Manakala di Malaysia pula, portal sebenarnya.my telah diwujudkan dibawah inisiatif Suruhanjaya Komunikasi dan Multimedia Malaysia (SKMM) yang bertindak sebagai pusat sehenti bagi rakyat Malaysia untuk menyemak kandungan berita (“Portal sebenarnya.my” n.d.).

Pembelajaran mesin telah digunakan dalam bidang berita palsu bagi mengesan dan mengklasifikasi berita palsu dengan menggunakan pelbagai teknik pengekstrakan fitur. Pengekstrakan fitur memainkan peranan penting dalam membangunkan model yang efektif dengan mengubah teks menjadi perkataan bernilai dengan teknik yang berbeza (Aziz & Dimililer 2020). Antara teknik pengekstrakan fitur yang sering digunakan dalam mengesan berita palsu adalah *Term Frequency – Inverse Document Frequency (TF-IDF)*, *CountVectorizer* dan *N-gram*. Pembelajaran ensemble merupakan sub bidang dalam pembelajaran mesin dan kerap menjadi perhatian. Ia membangunkan pengelas yang teguh dengan prestasi yang lebih baik dengan menggabungkan ramalan set pengelas (Aziz & Dimililer 2020). Hutan Rawak (RF), *XGBoost* dan *Voting* adalah antara model pembelajaran ensemble yang terkenal.

Dalam pengelasan teks yang merupakan data tidak berstruktur, terdapat dua (2) faktor yang mempengaruhi prestasi model iaitu teknik pengekstrakan fitur dan penggunaan model pembelajaran mesin. Berdasarkan pemerhatian pada kajian terdahulu, kebanyakan set data berita palsu yang digunakan didapati telah mencapai prestasi yang optimum. Gabungan teknik pengekstrakan fitur TF-IDF dan model pembelajaran mesin Hutan Rawak (RF) merupakan model terbaik yang dibangunkan oleh Kini (2021) pada set data Kaggle *Fake News Classifier* (kfnc), tetapi hanya mencapai ketepatan sebanyak 0.907. Manakala gabungan teknik TF-IDF dan model ensemble *Voting* boleh mencapai kadar ketepatan sehingga 100% pada set data ISOT (Elsaeed et al. 2021). Oleh itu, dapat dilihat selain daripada penggunaan set data, gabungan teknik pengekstrakan fitur dan model pembelajaran ensemble juga akan mempengaruhi prestasi model.

Oleh itu, kajian ini mencadangkan gabungan teknik pengekstrakan fitur TF-IDF dengan pembelajaran ensemble *Voting* (TifVot) untuk mengesan berita palsu menggunakan set data berita palsu yang baru, kfnc. Objektif kajian ini adalah untuk mengenal pasti kaedah pengekstrakan fitur dan model pembelajaran ensemble yang terbaik serta set hiperparameter model yang optimum untuk mengklasifikasi dan mengesan berita palsu.

Jurnal ini mengandungi lima (5) bahagian. Bahagian I membincangkan tentang latar belakang, permasalahan dan objektif kajian. Bahagian II menunjukkan kajian literatur berkenaan berita palsu, penggunaan teknik pengekstrakan fitur, model pembelajaran ensembel dan *Explainable AI* (xAI). Bahagian III berkaitan dengan metodologi yang digunakan dalam kajian ini. Bahagian IV menerangkan keputusan kajian dan perbincangan analisis kajian. Akhir sekali, Bahagian V ialah rumusan dan cadangan kajian.

II. KAJIAN KESUSASTERAAN

A. Berita Palsu

Berita palsu tidak mempunyai definisi umum walaupun dalam bidang kewartawanan (Zhou & Zafarani 2020). Gelfert (2018) menyatakan pemalsuan berita telah lama wujud dan mengikut perubahan kemajuan teknologi daripada kaedah telegraf pada abad ke-19 kepada algoritma media sosial semasa, telah mewujudkan kaedah penipuan dan pemalsuan yang baru. Khan et al. (2021) berpendapat berita palsu adalah ibarat akhbar tabloid yang sengaja memberikan maklumat palsu atau penipuan dan disebarikan melalui media cetak dan media sosial. Ianya direka untuk memanipulasi persepsi seseorang atau menjana pendapatan menerusi iklan dengan menarik pembaca.

Cara berkomunikasi dan berkongsi maklumat mengalami perubahan mendadak berikutan peningkatan aksesibiliti ke internet pada masa kini. Penggunaan media sosial semakin popular dan menjadi aliran masa kini (*trend*) untuk mengemaskini dan berkongsi maklumat (Paka et al. 2021). Zhang & Ghorbani (2020) turut menyatakan perkembangan pesat media sosial telah menyaksikan pertambahan bilangan berita palsu sejak beberapa tahun kebelakangan ini. Berita palsu mempunyai kesan yang mendalam kepada individu dan masyarakat. Aplikasi *WhatsApp* pula telah menjadi kegunaan orang ramai untuk berkongsi maklumat antara individu dan kumpulan. Namun, ianya juga telah menjadi salah satu medium untuk menyebarkan berita dan maklumat palsu oleh pihak yang tidak bertanggungjawab (Hasbullah et al. 2021).

B. Pengekstrakan Fitur

Teks adalah jenis data yang tidak berstruktur dan kompleks. Proses pengekstrakan fitur yang betul merupakan proses yang penting dalam menentukan kadar ketepatan model untuk mengklasifikasi data teks (Dzisevic & Sesok 2019; Sheikhi 2021). Pengekstrakan fitur adalah proses menukar teks kepada bentuk numerik dengan mengeluarkan senarai perkataan daripada data teks sebagai kata kunci. Seterusnya, berat perkataan dalam teks dikira dan membentuk vektor digital supaya dapat digunakan oleh model pembelajaran mesin (Waykole & Thakare 2018; Thaher et al. 2021). Terdapat beberapa

kaedah yang digunakan oleh para pengkaji antaranya frekuensi istilah *Term Frequency (TF)*, *Term Frequency – Inverse Document Frequency (TF-IDF)*, N-gram, sisipan perkataan (*word embedding*), *Part Of Speech (POS)-tags* dan lain-lain.

TF-IDF adalah kaedah yang kerap digunakan oleh pengkaji dalam capaian maklumat dan pemprosesan bahasa tabii (Ahmed et al. 2017; Kapusta et al. 2021; Mugdha et al. 2020). TF-IDF ialah skor kekerapan perkataan yang menyerlahkan perkataan yang lebih menarik (Srivastava 2020). Ia menentukan kepentingan sesuatu perkataan dalam dokumen/teks dalam bentuk matriks pemberat. Kepentingan perkataan meningkat apabila semakin banyak bilangan perkataan itu muncul. Namun, ia berlawanan dengan kekerapan perkataan dalam dokumen/teks tersebut. Perkataan yang mempunyai skor TF-IDF yang tinggi adalah perkataan penting untuk dokumen/teks tersebut (Kareem & Awan 2019; Kaur et al. 2020; Probiez et al. 2021).

CountVectorizer menggunakan teknik *Bag-Of-Words (BOW)* yang berdasarkan kekerapan sesuatu perkataan itu muncul dan seterusnya membentuk vektor (Indarapu et al. 2021; Verma et al. 2021). Pengekstrakan fitur *CountVectorizer* telah diaplikasi dalam kajian-kajian untuk mengesan berita palsu dan mendapat ketepatan yang tinggi (Patil 2022; Vijayaraghavan et al. 2020). Patel & Meehan (2021) berpendapat perbezaan utama antara *CountVectorizer* dan TF-IDF adalah teknik kiraan. *CountVectorizer* mengira bilangan istilah tersebut muncul dalam set data yang menyebabkan berat sebelah terhadap istilah yang paling kerap muncul. Manakala, teknik TF-IDF menimbang jumlah istilah dengan ukuran kekerapan ia berlaku dalam set data.

N-gram merupakan pendekatan dan analisis popular yang digunakan dalam bidang pemprosesan bahasa tabii (NLP) yang berasaskan perkataan dan aksara paling banyak digunakan (Ahmed et al. 2017). N-gram ialah urutan perkataan bersebelahan dengan panjang 'n' untuk menyimpan lebih banyak maklumat spatial dalam teks dan lebih bermakna berbanding perkataan individu (Kapusta et al. 2021; Yuslee & Abdullah 2021). Bigram mewakili dua (2) perkataan seperti "New York", "United States" manakala trigram mewakili tiga (3) perkataan seperti "New York Times", "President United States". Jadual 1 menunjukkan ringkasan kajian-kajian terdahulu yang menggunakan pelbagai kaedah pengekstrakan fitur.

Jadual 1 Ringkasan kajian-kajian terdahulu berdasarkan pengekstrakan fitur

Penulis, Tahun	Pengekstrakan Fitur	Algoritma
(Ahmed et al. 2017)	N-gram (TF & TF-IDF)	<ul style="list-style-type: none"> • <i>Stochastic Gradient Descent (SGD)</i> • Mesin Sokongan Vektor (SVM) • Mesin Sokongan Vektor Linear (LSVM) • K-jiran Terdekat (KNN) • Pohon Keputusan (DT) • Regresi Logistik (LR)

(Agudelo et al. 2018)	<ul style="list-style-type: none"> • TF-IDF • <i>CountVectorizer</i> 	<ul style="list-style-type: none"> • <i>Multinomial Naive Bayes</i> (MNB)
(Agarwal et al. 2019)	<ul style="list-style-type: none"> • TF-IDF • <i>Bag-of-Words</i> (BOW) • N-gram • <i>CountVectorizer</i> 	<ul style="list-style-type: none"> • <i>Naive Bayes</i> (NB) • Regresi Logistik (LR) • Mesin Sokongan Vektor (SVM) • <i>Stochastic Gradient Descent</i> (SGD) • Hutan Rawak (RF)
(Hussain et al. 2020)	<ul style="list-style-type: none"> • <i>CountVectorizer</i> • TF-IDF 	<ul style="list-style-type: none"> • <i>Multinomial Naive Bayes</i> (MNB) • Mesin Sokongan Vektor (SVM)
(Yuslee & Abdullah 2021)	<ul style="list-style-type: none"> • N-gram • TF-IDF • <i>CountVectorizer</i> 	<ul style="list-style-type: none"> • <i>Naive Bayes</i> (NB)

C. Pembelajaran Mesin

Pembelajaran mesin menggunakan algoritma untuk mengekstrak corak dengan menggunakan kaedah matematik, statistik, pengoptimuman dan penemuan pengetahuan yang merupakan langkah penting dalam pembelajaran mesin (Telikani et al. 2022). Algoritma dilatih terlebih dahulu dengan set data latihan. Selepas itu, ia digunakan untuk melakukan tugas yang berbeza seperti ramalan atau mengesan sesuatu yang tersembunyi. Mengesan berita palsu adalah tugas paling sukar sekiranya dibuat secara manual. Dengan menggunakan pembelajaran mesin, berita palsu dapat dikesan dengan mudah (Ahmed et al. 2021).

Model ensembel meningkatkan prestasi pengelasan keseluruhan dengan menggabungkan output set pengelas asas (Qasem et al. 2021). Secara teorinya, pengelas ensembel dapat mencapai prestasi lebih baik daripada pengelas tunggal kerana ianya menggabungkan beberapa algoritma pembelajaran dan membangunkan satu model ramalan yang optima serta menghasilkan ramalan yang lebih tepat dan mengurangkan ralat (Aziz & Dimililer 2020; Hakak et al. 2021). Kelebihan ini dapat meningkatkan keteguhan atau kebolehpercayaan dalam purata prestasi model (Ganesh et al. 2021).

Hutan Rawak (RF) mewujudkan set Pohon Keputusan (DT) yang tidak bergantung antara satu sama lain daripada set data latihan untuk membangunkan pengelas dan kelas ramalan untuk data ujian ditentukan berdasarkan undian daripada pelbagai DT. (Bentéjac et al. 2021; Vijayaraghavan et al. 2020). Umumnya, lebih banyak pohon, lebih teguh hutan itu dan dapat meningkatkan ketepatan (Waykole & Thakare 2018). Namun, bilangan pohon yang banyak menjadikan algoritma lebih perlahan dan tidak mampu menghadapi masalah pada masa nyata serta memerlukan lebih banyak sumber pengiraan dan kurang intuitif (Vinit Bhoir 2020). Di samping itu, RF boleh menyelesaikan masalah *overfitting* pada data latihan menggunakan pengelas pohon keputusan (Prakash et al. 2019).

XGBoost adalah ensembel pohon keputusan (DT) berdasarkan *gradient boosting* yang direka bentuk untuk berskala tinggi (Bentéjac et al. 2021). Algoritma ini mempunyai prestasi yang

cemerlang dalam data kecil hingga sederhana. Ia membina pohon keputusan selari untuk meningkatkan masa larian algoritma (Mamidanna et al. 2022). Teknik *boosting* mengurangkan ralat keseluruhan dan meningkatkan prestasi pengelasan dengan menambahkan model tambahan berdasarkan cara pengulangan yang menjadikan kaedah ini teknik yang berguna untuk pengelasan (Sheikhi 2021). Selain itu, *XGBoost* dibangunkan untuk mengendalikan nilai yang hilang, pengesahan silang dan lain-lain. Ia menunjukkan prestasi yang baik apabila digunakan dengan hiperparameter (Rao et al. 2021).

Voting merupakan prosedur ensembel yang paling asas dan agak berkesan. Ia boleh digunakan untuk isu klasifikasi dan regresi (Patil 2022). Gabungan dua atau lebih model pembelajaran yang dilatih pada keseluruhan set data. Setiap model meramalkan output kelas berdasarkan majoriti undian (Ganesh et al. 2021; Ribeiro Bezerra 2021). Teknik *Voting* juga dapat meminimumkan ralat dan *overfitting* (Verma et al. 2021). Kaedah *Voting* ini telah digunakan dalam beberapa tugas klasifikasi seperti pengesanan berita palsu, pengesanan spam dan analisis kestabilan cerun (Akhter et al. 2021). Jadual 2 menunjukkan ringkasan kajian-kajian terdahulu yang menggunakan pelbagai algoritma pembelajaran mesin dan ensembel.

Jadual 2 Ringkasan kajian-kajian terdahulu pengesanan berita palsu menggunakan pembelajaran mesin dan ensembel

Penulis, Tahun	Algoritma	Dapatan
(Reis et al. 2019)	KNN, NB, RF, SVM dan <i>XGBoost</i>	<i>XGBoost</i> menunjukkan prestasi terbaik. Ia boleh mengesan dengan betul hampir semua berita palsu.
(Al-Ash et al. 2019)	RF, SVM, MNB	RF (ensembel) peroleh 0.98 skor f1 lebih baik daripada MNB dan SVM pada 660 dokumen. Perbandingan dengan penyelidikan lain menggunakan data yang sama, mendapat keputusan yang lebih baik.
(Mahabub 2020)	<i>Gradient Boosting</i> , <i>Ada Boosting</i> , <i>Voting</i> , NB, KNN, SVM, RF, ANN, LR	Model <i>Voting</i> mencapai ketepatan 94.5%. Metrik penilaian lain cemerlang. Cadangan model berkesan mencari berita penting.
(Elsaeed et al. 2021)	NB, SVM, LR, RF, SGD, PA dan <i>Voting</i>	Model <i>Voting</i> mendapat ketepatan tertinggi sehingga 100% bagi semua set data yang digunakan.
(Mahmud et al. 2021)	NB, LR, SVM dan RF	RF mencapai ketepatan tertinggi (99.9%) berbanding algoritma lain.

D. Explainable Artificial Intelligence (xAI)

Penggunaan model pembelajaran mesin dianggap sebagai kotak hitam kepada pengguna (Alharbi et al. 2021; Ribeiro et al. 2016a). Pada masa ini, model sering dinilai menggunakan metrik ketepatan dan mungkin tidak mencapai objektif yang diperlukan. Penjelasan kepada ramalan model adalah sebagai tambahan kepada metrik penilaian yang digunakan (Ribeiro et al. 2016b). *Explainable Artificial Intelligence (xAI)* digunakan untuk membina dan menggunakan model yang boleh ditafsir dan difahami oleh pengguna. LIME adalah rangka kerja sumber terbuka untuk menjelaskan proses membuat keputusan model bagi mewujudkan kepercayaan (Dieber & Kirrane 2020). Menurut Ribeiro et al. (2016b), LIME menganggarkan secara setempat dengan model yang boleh ditafsir dan

mempersiapkan teks atau visual yang memberikan pemahaman kualitatif tentang hubungan antara komponen. Jadual 3 menunjukkan ringkasan kajian-kajian terdahulu yang menggunakan pendekatan xAI.

Jadual 3 Ringkasan kajian-kajian terdahulu yang menggunakan pendekatan xAI

Penulis, Tahun	Algoritma	Dapatan
(Szczeptański et al. 2021)	LIME dan Anchors	Menangkap corak yang bermakna berdasarkan tingkah laku model. Mendapat manfaat daripada menggunakan pelbagai kaedah untuk mencari corak yang bermakna.
(Alharbi et al. 2021)	Captum, LIME dan SHAP	Ketepatan yang tinggi mungkin bukan pilihan terbaik tetapi untuk menerangkan ramalan model dengan baik. xAI yang berbeza mentafsir ciri yang berbeza dan mungkin akan mengurangkan kepercayaan terhadap model.
(Ahmed et al. 2022)	LIME-BiLSTM	Ketepatan model mencapai 94.25%, mengatasi pendekatan pembelajaran mesin yang lain.

III. METODOLOGI KAJIAN

Rangka kerja kajian ini merangkumi tiga (3) fasa utama iaitu Fasa Input, Fasa Pembangunan Model dan Fasa Output. Gambaran menyeluruh bagi rangka kerja model pengesanan berita palsu ditunjukkan dalam Rajah 1.

A. Fasa Input

Fasa ini merangkumi proses mengenal pasti masalah kajian. Seterusnya, proses kajian kesusasteraan dilaksanakan yang mempertimbangkan kajian-kajian terdahulu dalam bidang berita palsu, pengekstrakan fitur, pembelajaran mesin dan *Explainable Artificial Intelligence (xAI)* bagi mendapatkan hala tuju kajian ini. Akhirnya, objektif, skop dan kepentingan kajian ditetapkan berdasarkan permasalahan yang telah dikenal pasti.

B. Fasa Pembangunan Model

Fasa ini merangkumi tiga (3) bahagian utama iaitu Penyediaan dan Analisis Data, Pengekstrakan Fitur dan Penalaan Parameter. Keterangan yang lebih terperinci adalah seperti berikut:

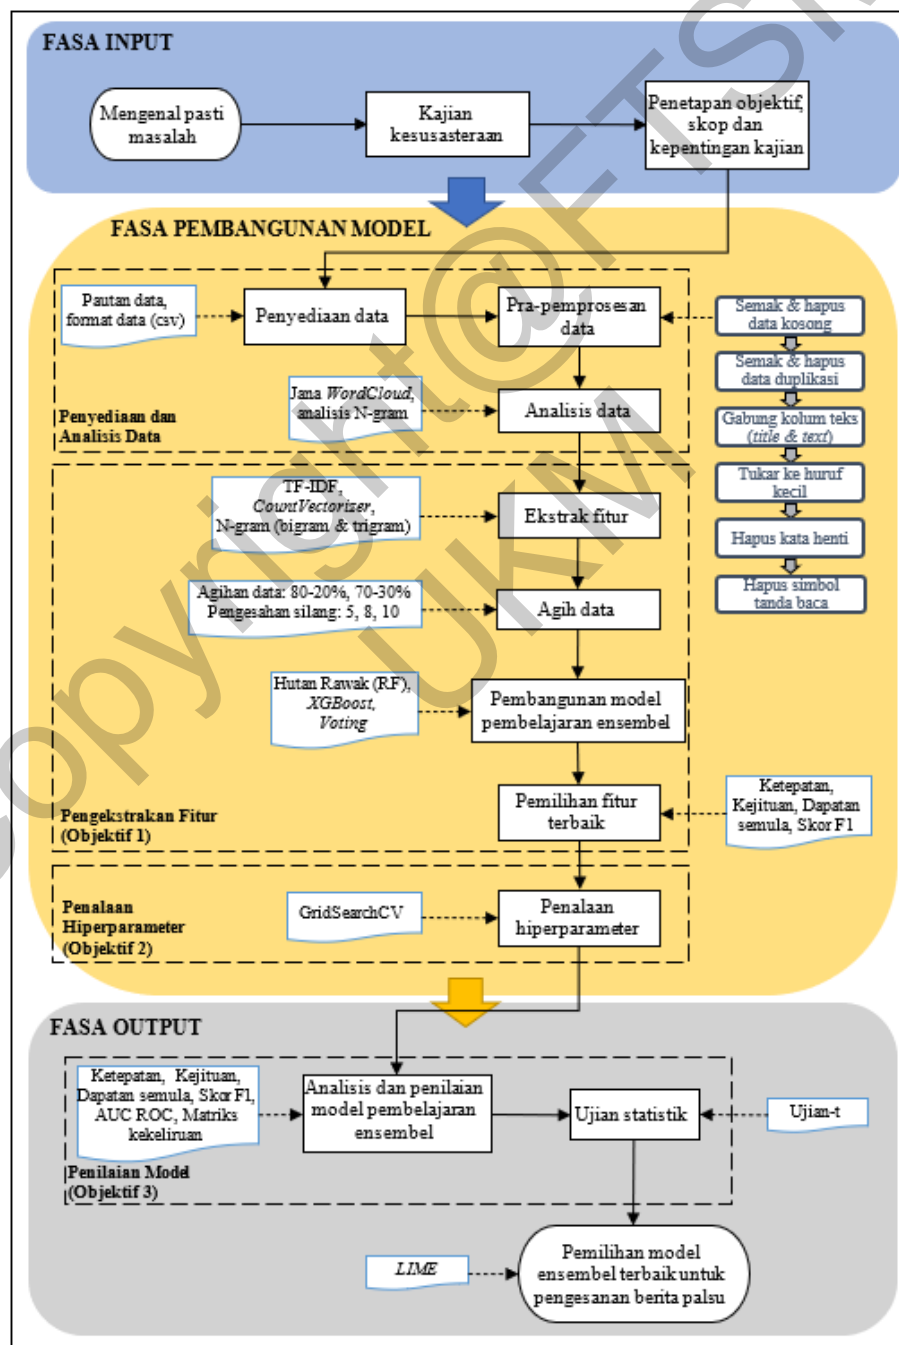
i. Penyediaan Data

Set data ini merupakan set data berita palsu yang baru kerana ianya baru dimuat naik oleh Hrishikesh Kini pada November 2021 di laman web Kaggle.com. Tiada keterangan lanjut mengenai data ini dan masih belum diterbitkan dalam mana-mana jurnal sepanjang pemerhatian yang dilakukan (Kini 2021). Set data ini disediakan dalam format *comma separated values (CSV)* yang mengandungi lima (5)

atribut dan 20,800 data. Jadual 4 menunjukkan senarai maklumat set data. Set data ini dianggap seimbang kerana terdiri daripada 10,413 data berita sahih dan 10,387 data berita palsu.

Jadual 4 Senarai maklumat set data

Bil	Atribut	Jenis	Keterangan
1	id	Integer	Nombor ID data
2	title	Teks	Mengandungi tajuk berita
3	author	Teks	Penulis berita
4	text	Teks	Isi kandungan berita
5	label	Integer	Nilai "0" mewakili berita palsu dan "1" mewakili berita sahih



Rajah 1 Rangka kerja pengesanan berita palsu

ii. Pra-Pemrosesan Data

Terdapat enam (6) proses dilaksanakan yang dapat membantu mengurangkan saiz data sebenar dengan mengeluarkan maklumat yang tidak berkaitan (Ahmed et al. 2018). Langkah-langkahnya adalah seperti berikut:

1. Semak dan hapus data kosong: sebanyak 558 data kosong dan dihapuskan.
2. Semak dan hapus data duplikasi: sebanyak 70 data duplikasi dan dihapuskan.
3. Gabung atribut “*title*” dan “*text*”: menggabungkan atribut “*title*” dan “*text*” menjadi satu atribut sebagai “*article*” bagi memudahkan proses pra-pemrosesan seterusnya.
4. Tukar data ke huruf kecil: semua perkataan ditukarkan kepada huruf kecil untuk keseragaman dan disimpan sebagai atribut “*article_lowercase*” untuk digunakan pada langkah seterusnya.
5. Hapus kata henti: perkataan yang selalu digunakan dan tidak memberi banyak maksud (Nikam & Dalvi 2020). Perpustakaan gensim digunakan dan disimpan sebagai atribut “*article_stopword*” untuk digunakan pada langkah seterusnya.
6. Hapus simbol tanda baca: simbol-simbol seperti , . ! @ kerap digunakan untuk membahagikan teks dan mempengaruhi keputusan pemrosesan teks (Etaiwi & Naymat 2017).

Data yang telah diproses disimpan sebagai “*article_clean*” dan digunakan untuk fasa seterusnya. Jadual 5 memaparkan rumusan jumlah data sebelum dan selepas proses pra-pemrosesan.

Jadual 5 Jumlah data sebelum dan selepas proses pra-pemrosesan

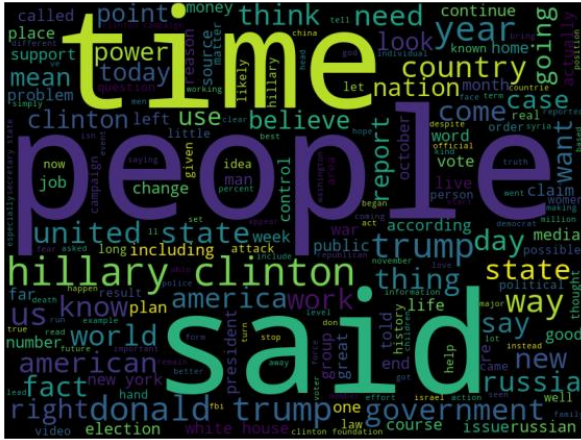
Label	“0”	“1”	Jumlah
Sebelum pra-pemrosesan	10,387	10,413	20,800
Selepas pra-pemrosesan	10,387	9,746	20,133

iii. Analisis Data


Word Cloud: visualisasi teks untuk menggambarkan tag atau kata kunci dalam dokumen/korpus yang dikelompokkan bersama yang dihasilkan daripada perpustakaan python “*WordCloud*”. Saiz huruf dan ton warna yang berbeza mewakili kepentingan perkataan tersebut. Lebih besar saiz, lebih tinggi kepentingan perkataan itu. Rajah 2 menunjukkan analisis bagi berita sahih. Analisis bagi berita palsu pula ditunjukkan di Rajah 3.

N-gram: dibina dengan mengira bilangan urutan perkataan tertentu muncul dalam dokumen. Bigram (2-gram) ialah gabungan dua perkataan manakala trigram ialah gabungan tiga perkataan (Chauhan & Palivela 2021). Rajah 4 menunjukkan visualisasi analisa 20 teratas kekerapan kata bigram bagi berita sahih dan perkataan “*hillary clinton*” paling banyak digunakan. Rajah 5 pula

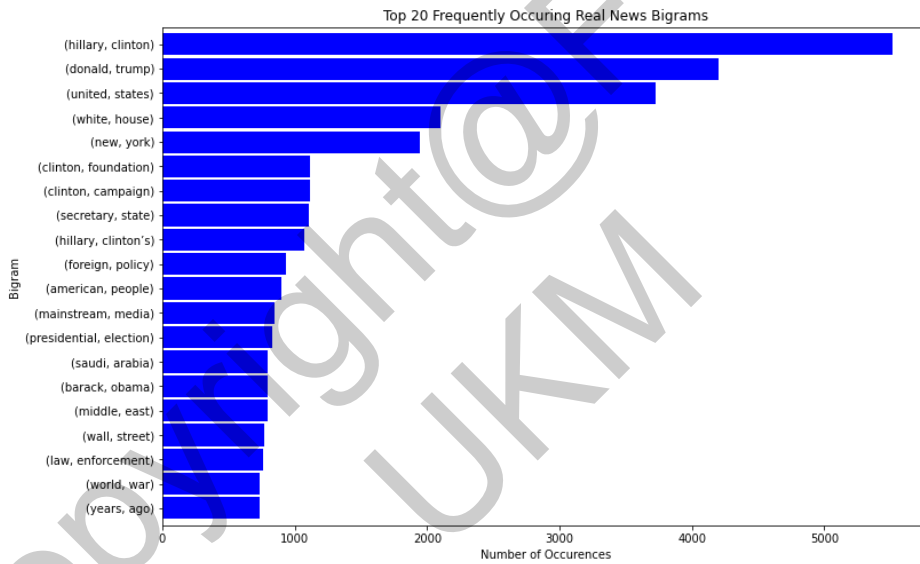
menunjukkan visualisasi analisa 20 teratas kekerapan kata bigram bagi berita palsu dan perkataan “new york” yang paling banyak digunakan.



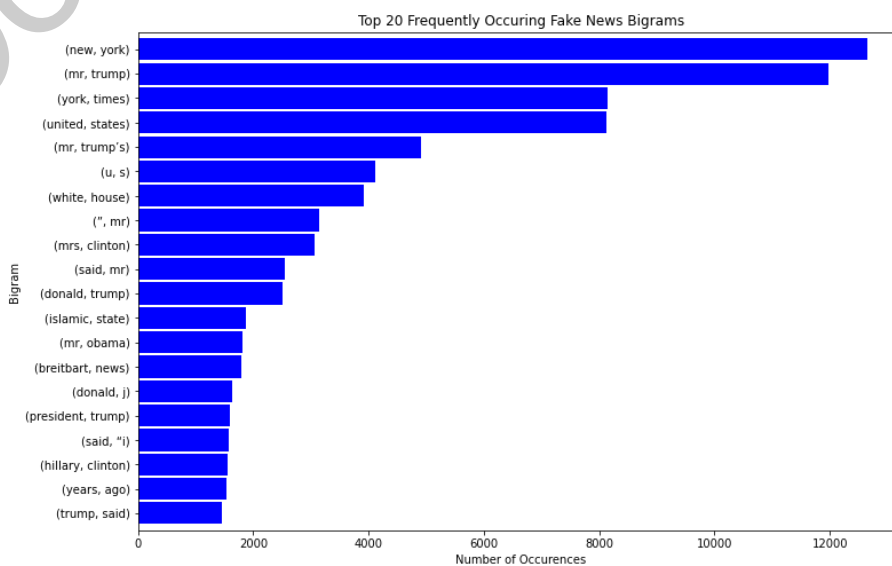
Rajah 2 Word cloud berita sahih



Rajah 3 Word cloud berita palsu

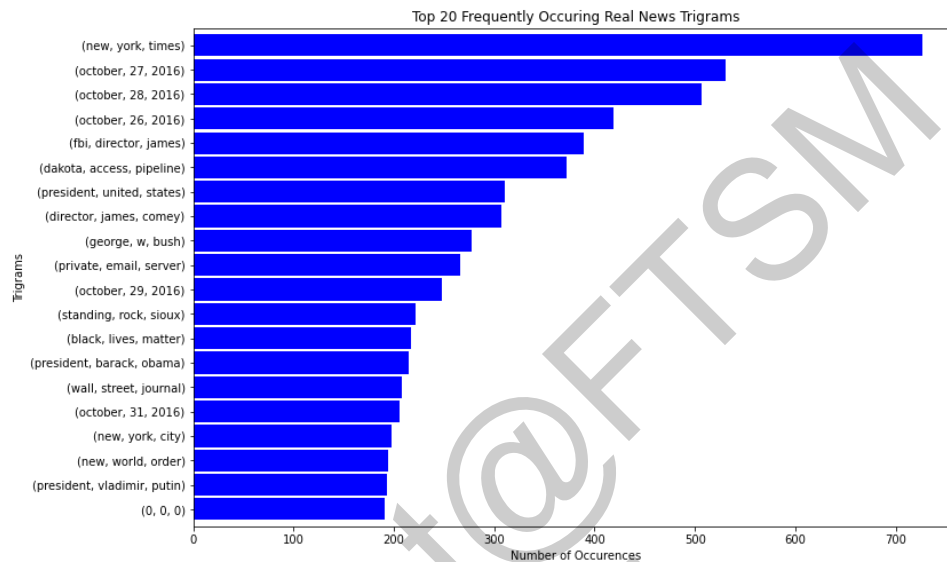


Rajah 4 Analisa bigram berita sahih

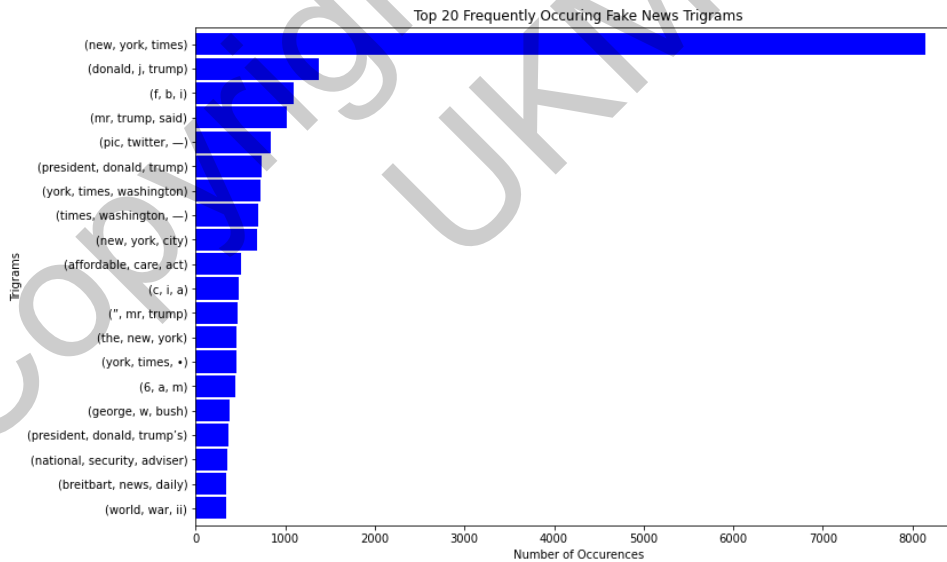


Rajah 5 Analisa bigram berita palsu

20 teratas kekerapan kata trigram bagi berita sahih ditunjukkan dalam Rajah 6 dan trigram bagi berita palsu ditunjukkan dalam Rajah 7. Kedua-dua rajah menunjukkan perkataan “*new york times*” merupakan perkataan yang paling kerap digunakan bagi berita sahih dan palsu. Penggunaan trigram juga dilihat lebih memberi maksud seperti perkataan “*new york times*” yang merujuk kepada surat khabar dan “*new york city*” merujuk kepada nama bandar.



Rajah 6 Analisa trigram berita sahih



Rajah 7 Analisa trigram berita palsu

iv. Ekstrak Fitur

Tiga (3) teknik dipilih berdasarkan penggunaan yang meluas dan berprestasi baik seperti berikut:

1. TF-IDF: menukarkan teks kepada angka untuk menentukan kepentingan perkataan dalam dokumen (Mugdha et al. 2020) dengan menggunakan perpustakaan python “*TfidfVectorizer*”.

2. *CountVectorizer*: mempelajari perbendaharaan kata daripada dokumen dan mengekstrak ciri kekerapan perkataan. Seterusnya, mewujudkan matriks dengan kiraan token untuk mewakili dokumen (Ahmed et al. 2018) dengan menggunakan perpustakaan python "*CountVectorizer*".
3. N-gram: membantu dalam menyediakan konteks kepada teks dengan menggabungkan perkataan berdekatan dan menghasilkan satu ciri (Agarwal et al. 2019). Saiz N-gram yang diuji adalah bigram ($n=2$) dan trigram ($n=3$) dengan mengubah saiz "*ngram_range*".

v. Agih Data

Kaedah agihan data yang digunakan ialah agihan data latihan-ujian (*train-test split*) dan pengesahan silang (*cross-validation*). Bagi agihan data latihan-ujian, set data dibahagikan kepada dua bahagian iaitu set data latihan dan set data ujian (Elsaeed et al. 2021). Ratio pengagihan data ialah 70%-30% dan 80-20% dan menggunakan perpustakaan python "*train_test_split()*". Bagi pengesahan silang pula, tiga (3) nilai *k-fold* akan diuji iaitu 5, 8 dan 10 dengan menggunakan perpustakaan python "*cross_validate()*".

vi. Pembangunan Model Pembelajaran Ensemble

Tiga (3) model dipilih berdasarkan penggunaan yang kerap dan meluas seperti berikut:

1. Hutan Rawak (RF): membina banyak pokok keputusan dan menggabungkannya. Seterusnya, membuat ramalan dengan purata ramalan setiap pokok komponen, yang menghasilkan ketepatan ramalan yang banyak (Mamidanna et al. 2022).
2. *XGBoost*: menggabungkan nilai daripada model-model untuk meramal sasaran pembolehubah dengan betul (Patil 2022).
3. *Voting*: mengambil input dari beberapa pengelas dan keputusan akhirnya mengambil kira setiap output pengelas. Kaedah "*soft voting*" digunakan yang mengaplikasi mekanisma wajaran berdasarkan ketepatan (Ribeiro Bezerra 2021).

vii. Pemilihan Fitur Terbaik

Bagi memilih pengekstrakan fitur terbaik, kaedah pengekstrakan fitur diuji pada ketiga-tiga model pembelajaran ensemble. Prestasi setiap model akan dinilai dengan metrik penilaian Ketepatan (*Accuracy*), Kejituan (*Precision*), Dapatan Semula (*Recall*) dan Skor F1 (*F1-score*). Kaedah terbaik dipilih berdasarkan skor purata tertinggi dan digunakan pada proses seterusnya.

viii. Penalaan Hiperparameter

Fungsi GridSearchCV digunakan untuk menala hiperparameter setiap algoritma berdasarkan kaedah pengekstrakan fitur terbaik. Grid nilai bagi setiap parameter diberikan sebagai input dan GridSearchCV membina dan menilai model secara berkaedah untuk setiap gabungan hiperparameter algoritma. Model dengan nilai hiperparameter terbaik diberikan sebagai output (Srivastava 2020).

C. Fasa Output

i. Analisis dan Penilaian Model Pembelajaran Ensemble

Prestasi model dianalisis dan dinilai berdasarkan empat (4) metrik penilaian iaitu Ketepatan (*Accuracy*), Kejituan (*Precision*), Dapatan Semula (*Recall*) dan Skor F1 (*F1-score*). Di samping itu, prestasi model turut diukur berdasarkan metrik penilaian Nilai Kawasan dibawah Lengkung-Receiver Operating Characteristic (AUC-ROC) dan matriks kekeliruan (*confusion matrix*). Seterusnya, ujian statistik dilaksanakan bagi mengenal pasti perbezaan ketiga-tiga model secara statistik dan signifikan atau salah satu lebih tinggi daripada yang lain. Dengan menggunakan aras keyakinan *two-tailed* sebanyak 0.05 bersamaan 95%, ketiga-tiga model dinilai berdasarkan set data ini. Skor *P-value* dibawah 0.05 (≤ 0.05) menunjukkan bahawa ketiga-tiga model ini adalah signifikan secara statistik pada tahap 0.05. Akhirnya, model pembelajaran ensemble terbaik dipilih.

ii. Explainable Artificial Intelligence (xAI)

Rangka kerja *Explainable Artificial Intelligence (xAI)* digunakan bagi mentafsir ramalan model. Pendekatan *Local Interpretable Model-Agnostic Explanations (LIME)* digunakan kepada contoh data yang dipilih secara rawak dengan menyerlahkan sepuluh (10) ciri teratas yang menyumbang paling banyak kepada ramalan model.

IV. KEPUTUSAN KAJIAN DAN PERBINCANGAN

A. TF-IDF

Keputusan prestasi TF-IDF mengikut model dengan tetapan agihan data latihan-ujian ditunjukkan dalam Jadual 6. Dengan mengambil kira skor purata bagi data ujian, bagi agihan data 70-30%, model *Voting* memperoleh skor purata tertinggi sebanyak 0.963. Diikuti dengan model *XGBoost* sebanyak 0.959 dan yang paling rendah adalah model RF iaitu 0.93. Bagi agihan data 80-20%, model *Voting*

mencapai skor purata tertinggi sebanyak 0.964 dan diikuti dengan model *XGBoost* sebanyak 0.96. Model RF mendapat skor purata paling rendah adalah iaitu 0.931.

Jadual 6 Keputusan prestasi TF-IDF mengikut model dengan tetapan agihan data latihan-ujian

Model	Agihan (%)	Data	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Purata
Hutan Rawak (RF)	70-30	Latihan	1	1	1	1	1
		Ujian	0.932	0.968	0.891	0.928	0.930
	80-20	Latihan	1	1	1	1	1
		Ujian	0.932	0.966	0.895	0.929	0.931
<i>XGBoost</i>	70-30	Latihan	0.973	0.963	0.982	0.972	0.973
		Ujian	0.959	0.945	0.974	0.959	0.959
	80-20	Latihan	0.972	0.962	0.980	0.971	0.971
		Ujian	0.960	0.945	0.974	0.959	0.960
<i>Voting</i>	70-30	Latihan	0.994	0.991	0.996	0.994	0.994
		Ujian	0.963	0.954	0.972	0.963	0.963
	80-20	Latihan	0.994	0.991	0.997	0.994	0.994
		Ujian	0.964	0.956	0.973	0.964	0.964

Keputusan prestasi TF-IDF mengikut model dengan tetapan pengesahan silang dipaparkan dalam Jadual 7. Model *Voting* memperoleh skor purata paling tinggi berbanding model lain. Diikuti dengan model *XGBoost* dan RF mendapat skor yang paling rendah.

Jadual 7 Keputusan prestasi TF-IDF mengikut model dengan tetapan pengesahan silang

Model	K-fold	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Purata
Hutan Rawak (RF)	5	0.940	0.963	0.911	0.936	0.938
	8	0.943	0.966	0.913	0.939	0.940
	10	0.941	0.964	0.911	0.937	0.938
<i>XGBoost</i>	5	0.965	0.955	0.975	0.965	0.965
	8	0.965	0.955	0.974	0.964	0.965
	10	0.966	0.955	0.976	0.965	0.966
<i>Voting</i>	5	0.970	0.961	0.977	0.969	0.969
	8	0.970	0.961	0.978	0.969	0.970
	10	0.970	0.961	0.977	0.969	0.969

Keseluruhannya, model *Voting* mencapai skor purata yang tertinggi bagi kedua-dua tetapan dengan tetapan pengesahan silang adalah lebih tinggi berbanding tetapan agihan data latihan-ujian.

B. COUNTVECTORIZER

Keputusan prestasi *CountVectorizer* mengikut model dengan tetapan agihan data latihan-ujian ditunjukkan dalam Jadual 8. Dengan mengambil kira skor purata bagi data ujian, bagi agihan data 70-30%, model *Voting* mencapai skor purata tertinggi sebanyak 0.965 dan diikuti dengan model *XGBoost* sebanyak 0.961. Model RF mendapat skor purata paling rendah adalah iaitu 0.92. Bagi agihan data

80-20%, model *Voting* memperoleh skor purata tertinggi sebanyak 0.965. Diikuti dengan model *XGBoost* sebanyak 0.959 dan yang paling rendah adalah model RF iaitu 0.926.

Jadual 8 Keputusan prestasi *CountVectorizer* mengikut model dengan tetapan agihan data latihan-ujian

Model	Agihan (%)	Data	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Purata
Hutan Rawak (RF)	70-30	Latihan	1	1	1	1	1
		Ujian	0.923	0.962	0.878	0.918	0.920
	80-20	Latihan	1	1	1	1	1
		Ujian	0.927	0.966	0.885	0.924	0.926
<i>XGBoost</i>	70-30	Latihan	0.970	0.957	0.981	0.969	0.969
		Ujian	0.961	0.946	0.976	0.961	0.961
	80-20	Latihan	0.969	0.956	0.980	0.968	0.968
		Ujian	0.959	0.943	0.976	0.959	0.959
<i>Voting</i>	70-30	Latihan	0.992	0.988	0.996	0.992	0.992
		Ujian	0.965	0.952	0.977	0.965	0.965
	80-20	Latihan	0.992	0.987	0.996	0.992	0.992
		Ujian	0.965	0.953	0.978	0.965	0.965

Jadual 9 memaparkan keputusan prestasi *CountVectorizer* mengikut model dengan tetapan pengesahan silang. Model *Voting* memperoleh skor purata paling tinggi berbanding model lain dan diikuti dengan model *XGBoost*. Model RF pula mendapat skor yang paling rendah.

Jadual 9 Keputusan prestasi *CountVectorizer* mengikut model dengan tetapan pengesahan silang

Model	<i>K-fold</i>	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Purata
Hutan Rawak (RF)	5	0.936	0.965	0.899	0.931	0.933
	8	0.936	0.963	0.901	0.931	0.933
	10	0.937	0.965	0.903	0.933	0.935
<i>XGBoost</i>	5	0.965	0.952	0.977	0.964	0.965
	8	0.964	0.951	0.977	0.964	0.964
	10	0.964	0.951	0.976	0.963	0.964
<i>Voting</i>	5	0.970	0.960	0.979	0.969	0.970
	8	0.970	0.959	0.980	0.969	0.970
	10	0.970	0.960	0.980	0.969	0.970

Keseluruhannya, model *Voting* mencapai skor purata yang tertinggi bagi kedua-dua tetapan dengan tetapan pengesahan silang adalah lebih tinggi berbanding tetapan agihan data latihan-ujian.

C. *N-GRAM*

i. Bigram

Jadual 10 menunjukkan keputusan prestasi *N-gram* (bigram) mengikut model dengan tetapan agihan

data latihan-ujian. Dengan mengambil kira skor purata bagi data ujian, bagi agihan data 70-30%, model RF memperoleh skor purata tertinggi sebanyak 0.947. Diikuti dengan model *Voting* sebanyak 0.941 dan yang paling rendah adalah model *XGBoost* iaitu 0.923. Bagi agihan data 80-20%, model RF mencapai skor purata tertinggi sebanyak 0.949 dan diikuti dengan model *Voting* sebanyak 0.94. Model *XGBoost* mendapat skor purata paling rendah adalah iaitu 0.922.

Jadual 10 Keputusan prestasi N-gram (bigram) mengikut model dengan tetapan agihan data latihan-ujian

Model	Agihan (%)	Data	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Purata
Hutan Rawak (RF)	70-30	Latihan	1	1	1	1	1
		Ujian	0.948	0.945	0.948	0.947	0.947
	80-20	Latihan	1	1	1	1	1
		Ujian	0.949	0.947	0.951	0.949	0.949
<i>XGBoost</i>	70-30	Latihan	0.929	0.894	0.967	0.929	0.930
		Ujian	0.921	0.887	0.960	0.923	0.923
	80-20	Latihan	0.928	0.893	0.967	0.928	0.929
		Ujian	0.919	0.888	0.960	0.922	0.922
<i>Voting</i>	70-30	Latihan	0.974	0.962	0.985	0.973	0.974
		Ujian	0.940	0.915	0.968	0.940	0.941
	80-20	Latihan	0.977	0.966	0.986	0.976	0.976
		Ujian	0.938	0.915	0.967	0.940	0.940

Keputusan prestasi N-gram (bigram) mengikut model dengan tetapan pengesahan silang dipaparkan dalam Jadual 11. Model RF memperoleh skor purata paling tinggi berbanding model lain. Diikuti dengan model *Voting* manakala *XGBoost* mendapat skor yang paling rendah.

Jadual 11 Keputusan prestasi N-gram (bigram) mengikut model dengan tetapan pengesahan silang

Model	K-fold	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Purata
Hutan Rawak (RF)	5	0.954	0.947	0.957	0.952	0.953
	8	0.954	0.949	0.955	0.952	0.953
	10	0.954	0.949	0.956	0.952	0.953
<i>XGBoost</i>	5	0.924	0.889	0.962	0.924	0.925
	8	0.924	0.891	0.962	0.925	0.926
	10	0.924	0.890	0.962	0.925	0.925
<i>Voting</i>	5	0.939	0.911	0.968	0.939	0.939
	8	0.941	0.915	0.968	0.941	0.941
	10	0.941	0.916	0.968	0.941	0.942

Keseluruhannya, model RF mencapai skor purata tertinggi bagi kedua-dua tetapan dengan tetapan pengesahan silang adalah lebih tinggi berbanding tetapan agihan data latihan-ujian.

ii. Trigram

Keputusan prestasi N-gram (trigram) mengikut model dengan tetapan agihan data latihan-ujian

ditunjukkan dalam Jadual 12. Dengan mengambil kira skor purata data ujian, bagi agihan data 70-30%, model RF mencapai skor purata tertinggi sebanyak 0.943 dan diikuti dengan *Voting* sebanyak 0.928. Model *XGBoost* mendapat skor purata paling rendah adalah iaitu 0.904. Bagi agihan data 80-20%, RF memperoleh skor purata tertinggi sebanyak 0.944. Diikuti dengan model *Voting* sebanyak 0.931 dan yang paling rendah adalah model *XGBoost* iaitu 0.907.

Jadual 12 Keputusan prestasi N-gram (trigram) mengikut model dengan tetapan agihan data latihan-ujian

Model	Agihan (%)	Data	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Purata
Hutan Rawak (RF)	70-30	Latihan	1	1	1	1	1
		Ujian	0.942	0.913	0.973	0.942	0.943
	80-20	Latihan	1	1	1	1	1
		Ujian	0.942	0.918	0.971	0.944	0.944
<i>XGBoost</i>	70-30	Latihan	0.899	0.853	0.955	0.901	0.902
		Ujian	0.900	0.860	0.951	0.903	0.904
	80-20	Latihan	0.902	0.858	0.955	0.904	0.905
		Ujian	0.902	0.868	0.949	0.907	0.907
<i>Voting</i>	70-30	Latihan	0.953	0.928	0.979	0.953	0.953
		Ujian	0.926	0.896	0.961	0.927	0.928
	80-20	Latihan	0.953	0.929	0.978	0.952	0.953
		Ujian	0.929	0.900	0.965	0.931	0.931

Jadual 13 memaparkan keputusan prestasi N-gram (trigram) mengikut model dengan tetapan pengesahan silang. Model RF memperoleh skor purata paling tinggi berbanding model lain dan diikuti dengan *Voting*. *XGBoost* pula mendapat skor yang paling rendah.

Jadual 13 Keputusan prestasi N-gram (trigram) mengikut model dengan tetapan pengesahan silang

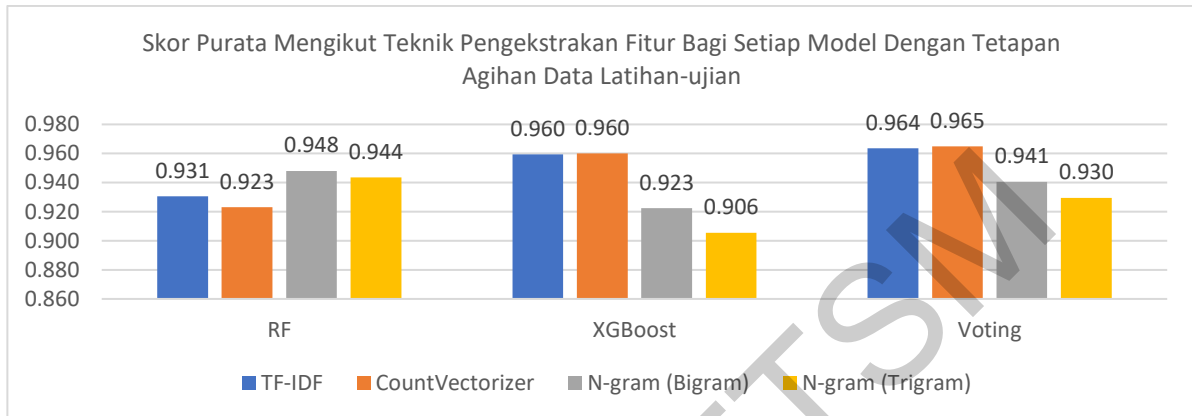
Model	K-fold	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Purata
Hutan Rawak (RF)	5	0.942	0.911	0.974	0.942	0.942
	8	0.943	0.913	0.975	0.943	0.944
	10	0.943	0.914	0.974	0.943	0.944
<i>XGBoost</i>	5	0.899	0.856	0.952	0.901	0.902
	8	0.900	0.857	0.952	0.902	0.903
	10	0.900	0.856	0.952	0.902	0.903
<i>Voting</i>	5	0.924	0.889	0.963	0.924	0.925
	8	0.925	0.892	0.962	0.926	0.926
	10	0.926	0.892	0.964	0.926	0.927

Keseluruhannya, model RF mencapai skor purata yang paling tinggi bagi kedua-dua tetapan.

D. Penilaian Prestasi Teknik Pengekstrakan Fitur

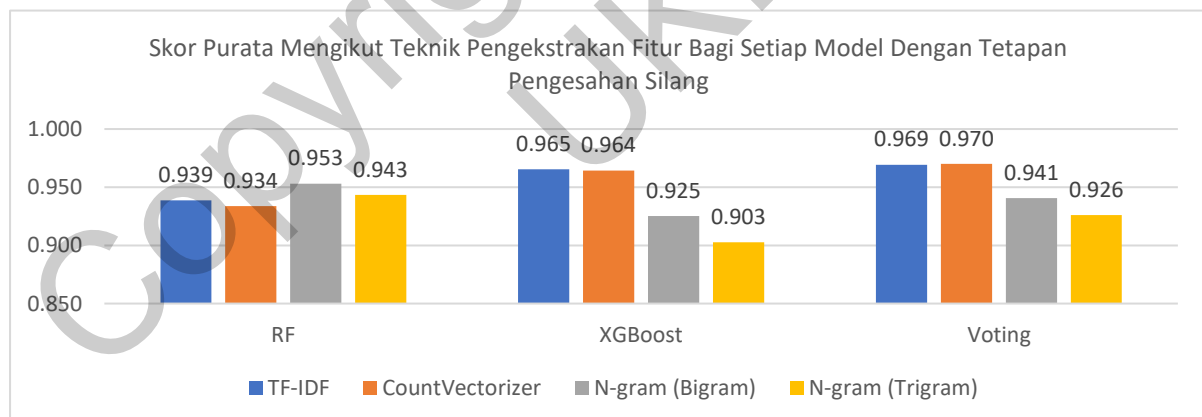
Rajah 8 menunjukkan perbandingan skor purata mengikut teknik pengekstrakan fitur bagi setiap model dengan tetapan agihan data latihan-ujian. Model RF mendapat skor purata tertinggi

menggunakan pengekstrakan fitur N-gram (bigram). Model *XGBoost* pula memperoleh skor purata tertinggi yang sama bagi teknik TF-IDF dan *CountVectorizer*. Manakala model *Voting* pula mendapat skor purata tertinggi menggunakan pengekstrakan fitur *CountVectorizer*.



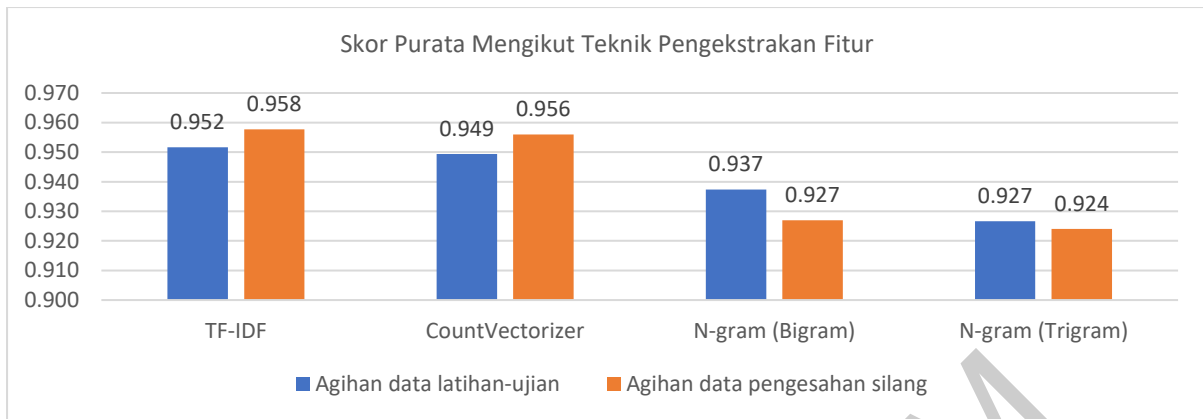
Rajah 8 Perbandingan skor purata ketepatan mengikut teknik pengekstrakan fitur bagi setiap model dengan tetapan agihan data latihan-ujian

Bagi ketetapan pengesahan silang, perbandingan skor purata mengikut teknik pengekstrakan fitur bagi setiap model dipaparkan dalam Rajah 9. Model RF mendapat skor purata tertinggi dengan menggunakan teknik pengekstrakan fitur N-gram (bigram). *XGBoost* mencapai skor purata tertinggi dengan menggunakan teknik TF-IDF. Manakala model *Voting* memperoleh ketepatan paling tinggi apabila menggunakan teknik *CountVectorizer*.



Rajah 9 Perbandingan skor purata ketepatan mengikut teknik pengekstrakan fitur bagi setiap model dengan tetapan pengesahan silang

Bagi memilih teknik pengekstrakan fitur terbaik, skor purata yang tertinggi diambil. Rajah 10 memaparkan perbandingan skor purata yang diperoleh bagi setiap teknik pengekstrakan fitur. Teknik TF-IDF mendapat skor purata tertinggi berbanding teknik-teknik lain bagi kedua-dua tetapan agihan data. Bagi teknik N-gram, keputusan mendapati semakin besar nilai n, semakin rendah skor purata yang diperolehi.



Rajah 10 Perbandingan skor purata bagi teknik pengekstrakan fitur

E. Penalaan Hiperparameter

Penalaan hiperparameter model diuji berulang kali menggunakan fungsi GridSearchCV untuk mengoptimalkan model bagi mencapai ketepatan yang maksimum. GridSearchCV mencari hiperparameter terbaik namun prosesnya mengambil masa. Oleh itu, hanya beberapa hiperparameter yang signifikan sahaja dipilih untuk ditala. Pemilihan hiperparameter adalah berbeza mengikut model. Keputusan penalaan hiperparameter ditunjukkan dalam Jadual 14.

Jadual 14 Keputusan penalaan hiperparameter


Model	Hiperparameter	Nilai penalaan	Keputusan
RF	'n_estimators'	300, 310	300
	'max_depth'	None, 2	None
	'min_samples_leaf'	1, 3	1
XGBoost	'learning_rate'	0.6, 1.0	0.6
	'subsample'	0.5, 1.0	1.0
	'min_child_weight'	0.5, 1.0	0.5
Voting	'n_estimators'	100, 300	300
	'learning_rate'	0.6, 1.0	0.6

F. Penilaian Prestasi Model Pembelajaran Ensemble


Bagi model Hutan Rawak (RF), skor terbaik (*best_score_*) yang dicapai ialah 0.946. Jadual 15 menunjukkan keputusan prestasi model RF pada data ujian. Skor purata yang diperolehi oleh model RF meningkat kepada 0.957 daripada 0.940. Rajah 11 menunjukkan plot graf AUC-ROC. Matriks kekeliruan pula ditunjukkan pada Rajah 12. Daripada rajah tersebut, sebanyak 1,959 data yang diramalkan palsu dan sebenarnya palsu. 1,832 data pula diramalkan sah dan sebenarnya sah. Manakala sebanyak 59 data diramalkan sah tetapi sebenarnya palsu dan 177 data sebenarnya sah tetapi diramalkan palsu.

Jadual 15 Keputusan prestasi model Hutan Rawak (RF)

Metrik Penilaian	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Skor Purata
Keputusan	0.944	0.972	0.911	0.941	0.957



Rajah 11 Plot graf AUC-ROC model RF

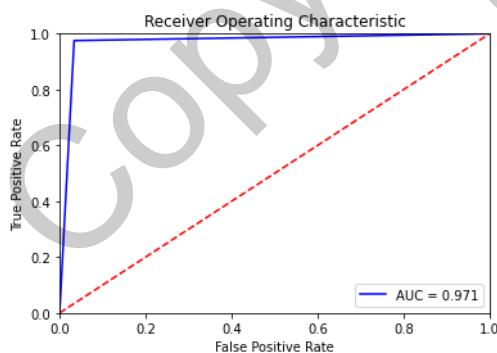


Rajah 12 Matriks kekeliruan model RF


Bagi model *XGBoost*, skor terbaik (*best_score_*) yang dapat dicapai ialah 0.975. Keputusan prestasi model *XGBoost* ditunjukkan dalam Jadual 16. Skor purata model *XGBoost* bertambah kepada 0.970 daripada 0.966. Graf Skor AUC-ROC diplotkan pada Rajah 13. Rajah 14 memaparkan matriks kekeliruan bagi model *XGBoost*. Sebanyak 1,946 data yang diramalkan palsu dan sebenarnya palsu. Data yang diramalkan sah dan sebenarnya sah adalah sebanyak 1,965. Manakala 72 data diramalkan sah tetapi sebenarnya palsu dan 44 data sebenarnya sah tetapi diramalkan palsu.

Jadual 16 Keputusan prestasi model XGBoost

Metrik Penilaian	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Purata
Keputusan	0.971	0.965	0.975	0.970	0.970



Rajah 13 Plot graf AUC-ROC model XGBoost




Rajah 14 Matriks kekeliruan model XGBoost

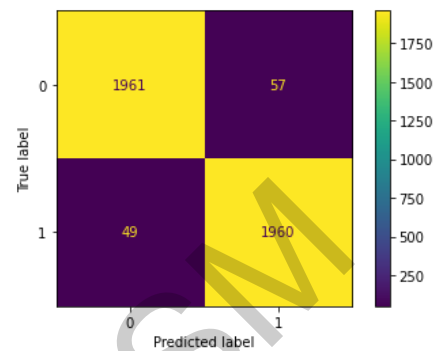
Model *Voting* pula, skor terbaik (*best_score_*) yang dapat dicapai ialah 0.979. Skor purata model *Voting* meningkat kepada 0.974 daripada 0.970. Jadual 17 menunjukkan keputusan prestasi model *Voting* dan graf AUC-ROC diplotkan pada Rajah 15. Matriks kekeliruan bagi model *Voting* ditunjukkan pada Rajah 16. Data yang diramalkan sah dan sebenarnya sah adalah sebanyak 1,960. Sebanyak 1,961 data yang diramalkan palsu dan sebenarnya palsu. Manakala 57 data diramalkan sah tetapi sebenarnya palsu dan 49 data sebenarnya sah tetapi diramalkan palsu.

Jadual 17 Keputusan prestasi model Voting

Metrik Penilaian	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Purata
Keputusan	0.974	0.972	0.976	0.974	0.974



Rajah 15 Plot graf AUC-ROC model Voting



Rajah 16 Matriks kekeliruan model Voting

G. Pemilihan Model Ensemble Terbaik

Jadual 18 memaparkan perbandingan prestasi model selepas proses penalaan hiperparameter dilakukan. Dapatan kajian mendapati bahawa model *Voting* (TifVot) mendapat skor purata tertinggi sebanyak 0.974 berbanding model lain. Seterusnya, diikuti dengan model *XGBoost* yang memperoleh skor purata sebanyak 0.970 dan terakhir model Hutan Rawak (RF) hanya mendapat skor purata paling rendah iaitu 0.957.

Jadual 18 Perbandingan prestasi model

Model	Ketepatan	Kejituan	Dapatan Semula	Skor F1	Skor Purata
Hutan Rawak (RF)	0.944	0.972	0.911	0.941	0.957
<i>XGBoost</i>	0.971	0.965	0.975	0.970	0.970
<i>Voting</i>	0.974	0.972	0.976	0.974	0.974

Keputusan kajian yang diperoleh pada Jadual 18 turut dibandingkan dengan model aras asas (*baseline model*) yang dibangunkan dan diuji oleh Kini (2021) di laman web Kaggle.com (Kini 2021). Jadual 19 menunjukkan perbandingan prestasi model aras asas. Hasil perbandingan menunjukkan model TifVot mencapai prestasi yang lebih baik iaitu 0.974 berbanding model aras asas yang hanya mendapat ketepatan tertinggi pada 0.907.

Jadual 19 Perbandingan prestasi model aras asas

Rujukan	Model	Teknik	Ketepatan
Model cadangan	TifVot	TF-IDF	0.974
Kini (2021)	Hutan Rawak (RF)	TF-IDF	0.907

H. Ujian Statistik

Jadual 20 menunjukkan keputusan ujian-t yang dilaksanakan. Berdasarkan keputusan yang diperolehi, model *Voting* menunjukkan keputusannya signifikan secara statistik pada aras nilai keyakinan 0.05.

Jadual 20 Keputusan ujian-t

Model	Nilai-p	Statistik-t
<i>Voting</i> & RF	0.002	-6.102
<i>Voting</i> & <i>XGBoost</i>	0.002	-6.196
RF & <i>XGboost</i>	0.002	-6.086

I. Explainable Artificial Intelligence (xAI)

Rangka kerja *Explainable Artificial Intelligence* (xAI) dengan pendekatan *Local Interpretable Model-Agnostic Explanations* (LIME) digunakan untuk menerangkan dan mentafsir ramalan model bagi meningkatkan kefahaman. Perkataan yang berwarna biru menunjukkan palsu manakala oren menunjukkan sah ditandakan pada artikel. LIME menggunakan pemberat dalam kebarangkalian ramalan yang menentukan samada berita tersebut adalah palsu atau sah. Dua (2) data dipilih secara rawak untuk ditafsirkan yang mewakili data sah dan palsu. Rajah 17 menunjukkan tafsiran ramalan LIME bagi model Hutan Rawak (RF) untuk data berita sah dan Rajah 18 bagi berita palsu.

Text with highlighted words

brandon turbeville interview voices network serena shim syria imperialism diogenes poverty ro obama's presidency contact read emails sent us busy respond many greatly appreciate feedback syndication wish reproduce essays site reproduce essays long proper attribution washingtons bl national security copyright notices national security notice calling overthrow government fact c government calling lawlessness calling end lawlessness lack accountability return rule law tryir enforcement patriotic americans born raised country love us dont seek destroy attack america

Rajah 17 Tafsiran LIME bagi model RF untuk berita sah

Text with highlighted words

reshaping lives congress new york times obama white house issued hundreds major regulations effort reshap american life important clean power plan year obama administration completed rules requiring nation's emis cut 2030 emissions greenhouse gases 32 percent 2005 levels rules central piece president's global effort con change fierce legal challenge stalled rules headed test supreme court fuel efficiency standards summer 2012 finished rules require cars light trucks get average nearly 55 miles gallon 2025 critics called rules costly un president obama said reduce oil consumption total 12 billion barrels 2025 regulations survived legal challen

Rajah 18 Tafsiran LIME bagi model RF untuk berita palsu

Bagi model *XGBoost*, Rajah 19 menunjukkan tafsiran ramalan LIME bagi data berita sah dan Rajah 20 bagi berita palsu. Bagi model *Voting*, Rajah 21 menunjukkan tafsiran ramalan LIME bagi data berita sah dan Rajah 22 bagi berita palsu.

Text with highlighted words

brandon turbeville interview voices network serena shim syria imperialism diogenes poverty r obama's presidency contact read emails sent us busy respond many greatly appreciate feedbac syndication wish reproduce essays site reproduce essays long proper attribution washingtons l national security copyright notices national security notice calling overthrow government fact government calling lawlessness calling end lawlessness lack accountability return rule law tryir enforcement patriotic americans born raised country love us dont seek destroy attack america

Rajah 19 Tafsiran LIME bagi model *XGBoost* untuk berita sah

Text with highlighted words

reshaping lives congress new york times obama white house issued hundreds major regulati american life important clean power plan year obama administration completed rul cut 2030 emissions greenhouse gases 32 percent 2005 levels rules central piece pre change fierce legal challenge stalled rules headed test supreme court fuel efficiency standards finished rules require cars light trucks get average nearly 55 miles gallon 2025 crit president obama said reduce oil consumption total 12 billion barrels 2025 regulatio

Rajah 20 Tafsiran LIME bagi model *XGBoost* untuk berita palsu

Text with highlighted words

brandon turbeville interview voices network serena shim syria imperialism diogenes poverty syndication wish reproduce essays site reproduce essays long proper attribution washington: national security copyright notices national security notice calling overthrow government fa government calling lawlessness calling end lawlessness lack accountability return rule law t enforcement patriotic americans born raised country love us dont seek destroy attack ameri enforcement patriotic americans born raised country love us dont seek destroy attack ameri

Rajah 21 Tafsiran LIME bagi model *Voting* untuk berita sah

Text with highlighted words

reshaping lives congress new york times obama white house issued hundreds major regulati american life important clean power plan year obama administration completed rules requirir cut 2030 emissions greenhouse gases 32 percent 2005 levels rules central piece president's gl change fierce legal challenge stalled rules headed test supreme court fuel efficiency standards finished rules require cars light trucks get average nearly 55 miles gallon 2025 critics called i president obama said reduce oil consumption total 12 billion barrels 2025 regulations survive

Rajah 22 Tafsiran LIME bagi model *Voting* untuk berita palsu

Jadual 21 menunjukkan perbandingan nilai kebarangkalian dan sepuluh (10) ciri perkataan bagi setiap model. Model *XGBoost* mencapai nilai kebarangkalian paling tinggi dalam mengklasifikasikan data berita sahih dan palsu. Model RF pula mendapat nilai kebarangkalian paling rendah berbanding model lain. Bagi pengekstrakan ciri perkataan pula, model *XGBoost* dan *Voting* mempunyai dua (2) perkataan teratas yang sama iaitu “*us*” dan “*dont*” bagi menentukan data tersebut adalah berita sahih. Manakala bagi data berita palsu pula, lima (5) perkataan teratas yang sama iaitu “*york*”, “*times*”, “*said*”, “*mr*” dan “*president*” dapat diekstrak oleh model *XGBoost* dan *Voting* bagi menentukan data tersebut adalah berita palsu.

Jadual 21 Perbandingan nilai kebarangkalian dan ciri bagi setiap model

	Hutan Rawak (RF)	XGBoost	Voting
Data Berita Sahih			
Kebarangkalian	Palsu (0): 0.14 Sahih (1): 0.86	Palsu (0): 0.02 Sahih (1): 0.98	Palsu (0): 0.07 Sahih (1): 0.93
Ciri	<p>0 1</p> <p>included 0.02 copyright 0.02 groups 0.02 dont 0.02 research 0.01 national 0.01 emails 0.01 house 0.01 security 0.01 country 0.01</p>	<p>0 1</p> <p>us 0.01 dont 0.01 government 0.00 prosperity 0.00 understanding 0.00 qaeda 0.00 security 0.00 groups 0.00 s 0.00 respond 0.00</p>	<p>0 1</p> <p>us 0.02 dont 0.01 think 0.01 interview 0.01 copyright 0.01 17 0.01 owner 0.01 title 0.01 calling 0.01 rose 0.00</p>
Data Berita Palsu			
Kebarangkalian	Palsu (0): 0.80 Sahih (1): 0.20	Palsu (0): 0.96 Sahih (1): 0.04	Palsu (0): 0.88 Sahih (1): 0.12
Ciri	<p>0 1</p> <p>new 0.06 york 0.06 said 0.05 times 0.03 officials 0.04 rules 0.04 critics 0.03 mr 0.03 called 0.03 administration 0.03</p>	<p>0 1</p> <p>york 0.48 times 0.27 said 0.16 mr 0.09 president 0.06 rules 0.03 set 0.01 advisers 0.01 drones 0.01 2015 0.01</p>	<p>0 1</p> <p>york 0.26 times 0.15 said 0.11 mr 0.07 president 0.04 court 0.02 administration 0.02 companies 0.02 people 0.02 rules 0.01</p>

J. Perbincangan

Tiga (3) teknik pengekstrakan fitur menunjukkan prestasi berbeza yang disebabkan oleh tingkah laku dan ciri algoritma yang berbeza serta penggunaan model yang berlainan turut mempengaruhi prestasi. Oleh itu, pemilihan teknik yang betul adalah penting bagi meningkatkan prestasi model. Dalam kajian

ini, TF-IDF merupakan teknik pengekstrakan fitur terbaik dalam mengesan berita palsu kerana dapat mencari corak perkataan yang paling berkesan dalam set data untuk menentukan berita palsu.

Dapatan kajian juga mendapati model *Voting* mempunyai prestasi paling baik. Penggabungan dua (2) model yang dilatih dapat menghasilkan prestasi lebih baik berbanding menggunakan model tunggal. Manakala Hutan Rawak (RF) memperoleh prestasi paling rendah. Data teks yang tidak berstruktur dan berterabur menyebabkan model tidak dapat berfungsi secara optimum. RF juga tidak dapat mengekstrak ciri dengan baik bagi kebarangkalian ramalan dalam menentukan berita palsu atau sahih berdasarkan analisis LIME.

V. RUMUSAN DAN CADANGAN

Gabungan teknik TF-IDF dan model *Voting* merupakan teknik terbaik dengan skor purata tertinggi sebanyak 0.974 dan disokong oleh keputusan ujian statistik yang signifikan secara statistik berbanding model lain. Dengan ini, diharap dapatan kajian dapat membantu penyelidik lain dalam mengenal pasti teknik pengekstrakan fitur dan model pembelajaran ensembel bagi mengesan berita palsu. Selain itu, diharapkan dapat menjadi panduan kepada pihak lain seperti Suruhanjaya Komunikasi Multimedia Malaysia (SKMM) supaya proses mengesan dan mengenal pasti berita palsu dapat dilakukan dengan mudah, cepat dan pantas. Set data yang digunakan adalah data berita palsu daripada sumber terbuka laman web Kaggle.com dan tertumpu kepada tiga (3) algoritma sahaja. Oleh itu, pada kajian akan datang dicadangkan untuk menggunakan data berita di Malaysia atau meluaskan jenis data seperti gambar/imej dan video. Peluasan penggunaan teknik pengekstrakan fitur yang lain dan penggunaan model lain juga boleh dipertimbangkan seperti penggunaan model ensembel yang lain atau pembelajaran mendalam.

PENGHARGAAN

Syukur Alhamdulillah serta terima kasih kepada penyelia projek, Ts. Dr. Nor Samsiah Sani di atas segala dorongan serta para pensyarah lain. Setinggi penghargaan kepada keluarga kerana sokongan yang tidak berbelah bahagi. Tidak lupa juga kepada rakan-rakan seperjuangan yang banyak berkongsi ilmu dan maklumat. Akhir sekali, terima kasih kepada Fakulti Sains Teknologi dan Maklumat, Universiti Kebangsaan Malaysia kerana memberikan peluang untuk menjalankan kajian ini.

RUJUKAN

Agarwal, V., Sultana, H.P., Malhotra, S. & Sarkar, A. 2019. Analysis of Classifiers for Fake News Detection.

Procedia Computer Science 165(2019): 377–383.

- Agudelo, G.E.R., Parra, O.J.S. & Velandia, J.B. 2018. Raising a model for fake news detection using machine learning in Python. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 11195 LNCS: 596–604.
- Ahmad, I., Yousaf, M., Yousaf, S. & Ahmad, M.O. 2020. Fake News Detection Using Machine Learning Ensemble Methods. (M. I. Uddin, Ed.) *Complexity* 2020: 1–11. <https://www.hindawi.com/journals/complexity/2020/8885861/>.
- Ahmed, A.A.A., Aljabouh, A., Donepudi, P.K. & Choi, M.S. 2021. Detecting Fake News Using Machine Learning : A Systematic Literature Review. *Psychology and Education Journal* 58(1): 1932–1939. <http://arxiv.org/abs/2102.04458>.
- Ahmed, H., Traore, I. & Saad, S. 2017. Detection of Online Fake News Using N-Gram Analysis and Machine Learning Techniques. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 10618 LNCS(October): 127–138.
- Ahmed, H., Traore, I. & Saad, S. 2018. Detecting opinion spams and fake news using text classification. *Security and Privacy* 1(1): e9.
- Akhter, M.P., Zheng, J., Afzal, F., Lin, H., Riaz, S. & Mehmood, A. 2021. Supervised ensemble learning methods towards automatically filtering Urdu fake news within social media. *PeerJ Computer Science* 7: 1–24.
- Al-Ash, H.S., Putri, M.F., Mursanto, P. & Bustamam, A. 2019. Ensemble Learning Approach on Indonesian Fake News Classification. *ICICOS 2019 - 3rd International Conference on Informatics and Computational Sciences: Accelerating Informatics and Computational Research for Smarter Society in The Era of Industry 4.0, Proceedings*
- Alameri, S.A. & Mohd, M. 2021. Comparison of Fake News Detection using Machine Learning and Deep Learning Techniques. *2021 3rd International Cyber Resilience Conference, CRC 2021 (Mcmc)*
- Alharbi, R., Vu, M.N. & Thai, M.T. 2021. Evaluating Fake News Detection Models from Explainable Machine Learning Perspectives. *IEEE International Conference on Communications*
- Aziz, R.H.H. & Dimililer, N. 2020. Twitter Sentiment Analysis using an Ensemble Weighted Majority Vote Classifier. *3rd International Conference on Advanced Science and Engineering, ICOASE 2020* 103–109.
- Bentéjac, C., Csörgő, A. & Martínez-Muñoz, G. 2021. *A comparative analysis of gradient boosting algorithms. Artificial Intelligence Review* Vol. 54. Springer Netherlands. <https://doi.org/10.1007/s10462-020-09896-5>.
- Castillo, J.M., Fadera, K.D.F., Ladao, A.A.A., Go, J.G., Tamayo, M.B. & Octaviano, M. V. 2021. Fake News Detection on English News Article's Title. *Proceedings - 2021 1st International Conference in Information and Computing Research, iCORE 2021* hlm. 151–156. IEEE.
- Chauhan, T. & Palivela, H. 2021. Optimization and improvement of fake news detection using deep learning approaches for societal benefit. *International Journal of Information Management Data Insights* 1(2): 100051. <https://doi.org/10.1016/j.ijime.2021.100051>.
- Coste, C.I. & Bufeana, D. 2021. Advances in clickbait and fake news detection using new language-independent strategies. *Journal of Communications Software and Systems* 17(3): 270–280.
- Dieber, J. & Kirrane, S. 2020. Why model why? Assessing the strengths and limitations of LIME (iii) <http://arxiv.org/abs/2012.00093>.
- Dong, X., Yu, Z., Cao, W., Shi, Y. & Ma, Q. 2020. A survey on ensemble learning. *Frontiers of Computer Science* 14(2): 241–258.
- Dzisevic, R. & Sesok, D. 2019. Text Classification using Different Feature Extraction Approaches. *2019 Open Conference of Electrical, Electronic and Information Sciences, eStream 2019 - Proceedings* 1–4.
- Elsaeed, E., Ouda, O., Elmogy, M.M., Atwan, A. & El-Daydamony, E. 2021. Detecting Fake News in Social Media Using Voting Classifier. *IEEE Access* 9: 161909–161925.
- Etaiwi, W. & Naymat, G. 2017. The Impact of applying Different Preprocessing Steps on Review Spam

- Detection. *Procedia Computer Science* 113: 273–279. <http://dx.doi.org/10.1016/j.procs.2017.08.368>.
- Ganesh, P., Priya, L. & Nandakumar, R. 2021. Fake News Detection - A Comparative Study of Advanced Ensemble Approaches. *Proceedings of the 5th International Conference on Trends in Electronics and Informatics, ICOEI 2021* 1003–1008.
- Gelfert, A. 2018. Fake news: A definition. *Informal Logic* 38(1): 84–117.
- Giri, M., Aditya, T., Honnavalli, P.B. & Eswaran, S. 2022. Automated and Interpretable Fake News Detection with Explainable Artificial Intelligence. *SSRN Electronic Journal*
- Granik, M. & Mesyura, V. 2017. Fake news detection using naive Bayes classifier. *2017 IEEE 1st Ukraine Conference on Electrical and Computer Engineering, UKRCON 2017 - Proceedings* 900–903.
- Hakak, S., Alazab, M., Khan, S., Gadekallu, T.R., Maddikunta, P.K.R. & Khan, W.Z. 2021. An ensemble machine learning approach through effective feature extraction to classify fake news. *Future Generation Computer Systems* 117: 47–58. <https://doi.org/10.1016/j.future.2020.11.022>.
- Hasbullah, N.A., Wook, M., Mat Razali, N.A., Zainudin, N.M. & Ramli, S. 2021. Review on Fake News in Malaysia during the Movement Control Order (MCO) from the Ethics in ICT Perspective. *2021 9th International Conference on Information and Education Technology, ICIET 2021* 461–465.
- Hussain, M.G., Rashidul Hasan, M., Rahman, M., Protim, J. & Al Hasan, S. 2020. Detection of Bangla Fake News using MNB and SVM Classifier. *Proceedings - 2020 International Conference on Computing, Electronics and Communications Engineering, iCCECE 2020* 81–85.
- Indarapu, S.R.K., Komalla, J., Inugala, D.R., Reddy Kota, G. & Sanam, A. 2021. Comparative analysis of machine learning algorithms to detect fake news. *2021 3rd International Conference on Signal Processing and Communication, ICPSC 2021 (May)*: 591–594.
- Jain, A., Shakya, A., Khatter, H. & Gupta, A.K. 2019. A smart System for Fake News Detection Using Machine Learning. *IEEE International Conference on Issues and Challenges in Intelligent Computing Techniques, ICICT 2019* 2–5.
- Kapusta, J., Drlik, M. & Munk, M. 2021. Using of n-grams from morphological tags for fake news classification. *PeerJ Computer Science* 7: 1–27.
- Kareem, I. & Awan, S.M. 2019. Pakistani Media Fake News Classification using Machine Learning Classifiers. *3rd International Conference on Innovative Computing, ICIC 2019 (Icic)*: 1–6.
- Kaur, S., Kumar, P. & Kumaraguru, P. 2020. Automating fake news detection system using multi-level voting model. *Soft Computing* 24(12): 9049–9069. <https://doi.org/10.1007/s00500-019-04436-y>.
- Khan, J.Y., Khondaker, M.T.I., Afroz, S., Uddin, G. & Iqbal, A. 2021. A benchmark study of machine learning models for online fake news detection. *Machine Learning with Applications* 4(March): 100032. <https://doi.org/10.1016/j.mlwa.2021.100032>.
- Kini, H. 2021. Set Data Kaggle - Fake News. *Kaggle* <https://www.kaggle.com/code/hrishikeshkini/fake-news-classifiers/data?select=train.csv>.
- Li, K. 2021. Haha at fakedes 2021: A fake news detection method based on tf-idf and ensemble machine learning. *CEUR Workshop Proceedings* Vol. 2943, hlm. 630–638 http://ceur-ws.org/Vol-2943/fakedes_paper5.pdf.
- Mahabub, A. 2020. A robust technique of fake news detection using Ensemble Voting Classifier and comparison with other classifiers. *SN Applied Sciences* 2(4): 1–9. <https://doi.org/10.1007/s42452-020-2326-y>.
- Mamidanna, S.K., Reddy, C.R.K. & Gujju, A. 2022. Detecting an Insider Threat and Analysis of XGBoost using Hyperparameter tuning. *2022 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI)* hlm. 1–10. IEEE.
- Mandical, R.R., Mamatha, N., Shivakumar, N., Monica, R. & Krishna, A.N. 2020. Identification of Fake News Using Machine Learning. *Proceedings of CONECCT 2020 - 6th IEEE International Conference on Electronics, Computing and Communication Technologies*

- Mugdha, S.B.S., Ferdous, S.M. & Fahmin, A. 2020. Evaluating Machine Learning Algorithms for Bengali Fake News Detection. *ICCIT 2020 - 23rd International Conference on Computer and Information Technology, Proceedings* (December): 19–21.
- Nikam, S.S. & Dalvi, R. 2020. Machine learning algorithm based model for classification of fake news on twitter. *Proceedings of the 4th International Conference on IoT in Social, Mobile, Analytics and Cloud, ISMAC 2020* hlm. 441–448
- Paka, W.S., Bansal, R., Kaushik, A., Sengupta, S. & Chakraborty, T. 2021. Cross-SEAN: A cross-stitch semi-supervised neural attention model for COVID-19 fake news detection. *Applied Soft Computing* 107: 107393. <https://doi.org/10.1016/j.asoc.2021.107393>.
- Patel, A. & Meehan, K. 2021. Fake News Detection on Reddit Utilising CountVectorizer and Term Frequency-Inverse Document Frequency with Logistic Regression, MultinomialNB and Support Vector Machine. *2021 32nd Irish Signals and Systems Conference, ISSC 2021*
- Patil, D.R. 2022. Fake News Detection Using Majority Voting Technique <http://arxiv.org/abs/2203.09936>.
- Portal sebenarnya.my. (t.th.). <https://sebenarnya.my/>.
- Prakash, P.B., Kumar, M.P., VenkataManaswini, G. & Mehata, K.M. 2019. Fake data analysis and detection using ensemble hybrid algorithm. *Proceedings of the 3rd International Conference on Computing Methodologies and Communication, ICCMC 2019* (Iccmc): 890–897.
- Probierz, B., Stefanski, P. & Kozak, J. 2021. Rapid detection of fake news based on machine learning methods. *Procedia Computer Science* 192: 2893–2902.
- Qasem, S.N., Al-Sarem, M. & Saeed, F. 2021. An ensemble learning based approach for detecting and tracking COVID19 rumors. *Computers, Materials and Continua* 70(1): 1721–1747.
- Qawasmeh, E., Tawalbeh, M. & Abdullah, M. 2019. Automatic Identification of Fake News Using Deep Learning. *2019 6th International Conference on Social Networks Analysis, Management and Security, SNAMS 2019* 383–388.
- Rao, V.C.S., Radhika, P., Polala, N. & Kiran, S. 2021. Logistic Regression versus XGBoost: Machine Learning for Counterfeit News Detection. *2021 2nd International Conference on Smart Technologies in Computing, Electrical and Electronics, ICSTCEE 2021 - Proceedings* 1–6.
- Ribeiro Bezerra, J.F. 2021. Content-based fake news classification through modified voting ensemble. *Journal of Information and Telecommunication* 5(4): 499–513. <https://doi.org/10.1080/24751839.2021.1963912>.
- Ribeiro, M.T., Singh, S. & Guestrin, C. 2016a. Model-Agnostic Interpretability of Machine Learning (Whi) <http://arxiv.org/abs/1606.05386>.
- Ribeiro, M.T., Singh, S. & Guestrin, C. 2016b. “Why Should I Trust You?” Explaining the Predictions of Any Classifier. *NAACL-HLT 2016 - 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Proceedings of the Demonstrations Session* 97–101.
- Sagi, O. & Rokach, L. 2018. Ensemble learning: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* 8(4): 1–18.
- Sangamnerkar, S., Srinivasan, R., Christhuraj, M.R. & Sukumaran, R. 2020. An ensemble technique to detect fabricated news article using machine learning and natural language processing techniques. *2020 International Conference for Emerging Technology, INCET 2020* 1–7.
- Shaikh, J. & Patil, R. 2020. Fake news detection using machine learning. *Proceedings - 2020 IEEE International Symposium on Sustainable Energy, Signal Processing and Cyber Security, iSSSC 2020* Vol. 2020
- Sharma, K., Qian, F., Jiang, H., Ruchansky, N., Zhang, M. & Liu, Y. 2019. Combating fake news: A survey on identification and mitigation techniques. *ACM Transactions on Intelligent Systems and Technology* 10(3)
- Sheikhi, S. 2021. An effective fake news detection method using WOA-xgbTree algorithm and content-based features. *Applied Soft Computing* 109: 107559. <https://doi.org/10.1016/j.asoc.2021.107559>.

- Srivastava, A. 2020. Real Time Fake News Detection Using Machine Learning and NLP. *International Research Journal of Engineering and Technology* www.irjet.net.
- Szczepański, M., Pawlicki, M., Kozik, R. & Choraś, M. 2021. New explainability method for BERT-based model in fake news detection. *Scientific Reports* 11(1): 1–13. <https://doi.org/10.1038/s41598-021-03100-6>.
- Telikani, A., Tahmassebi, A., Banzhaf, W. & Gandomi, A.H. 2022. Evolutionary Machine Learning: A Survey. *ACM Computing Surveys* 54(8)
- Thaher, T., Saheb, M., Turabieh, H. & Chantar, H. 2021. Intelligent detection of false information in arabic tweets utilizing hybrid harris hawks based feature selection and machine learning models. *Symmetry* 13(4)
- Theophilo, A., Padilha, R., Andaló, F.A. & Rocha, A. 2022. Explainable Artificial Intelligence for Authorship Attribution on Social Media. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*
- Umer, M., Imtiaz, Z., Ullah, S., Mehmood, A., Choi, G.S. & On, B.W. 2020. Fake news stance detection using deep learning architecture (CNN-LSTM). *IEEE Access* 8: 156695–156706.
- Verma, P.K., Agrawal, P., Amorim, I. & Prodan, R. 2021. WELFake: Word Embedding over Linguistic Features for Fake News Detection. *IEEE Transactions on Computational Social Systems* 8(4): 881–893.
- Vijayaraghavan, S., Wang, Y., Guo, Z., Voong, J., Xu, W., Nasser, A., Cai, J., Li, L., Vuong, K. & Wadhwa, E. 2020. Fake News Detection with Different Models <http://arxiv.org/abs/2003.04978>.
- Vinit Bhoir, S. 2020. An efficient fake news detector. *2020 International Conference on Computer Communication and Informatics, ICCCI 2020*
- Waykole, R.N. & Thakare, A.D. 2018. A REVIEW OF FEATURE EXTRACTION METHODS FOR TEXT CLASSIFICATION. *International Journal of Advance Engineering and Research Development* 5(04): 351–354.
- Yuslee, N.S. & Abdullah, N.A.S. 2021. Fake News Detection using Naive Bayes. *2021 IEEE 11th International Conference on System Engineering and Technology, ICSET 2021 - Proceedings* (November): 112–117.
- Zhang, X. & Ghorbani, A.A. 2020. An overview of online fake news: Characterization, detection, and discussion. *Information Processing and Management* 57(2): 102025. <https://doi.org/10.1016/j.ipm.2019.03.004>.
- Zhou, X. & Zafarani, R. 2020. A Survey of Fake News: Fundamental Theories, Detection Methods, and Opportunities. *ACM Computing Surveys* 53(5)