

Klasifikasi Komentar Video Instruksional Populer Bertemakan Pekarangan Perkotaan menggunakan Auto-Keras

Trisna Gelar^{*1)}, Aprianti Nanda Sari²⁾

Jurusan Teknik Komputer dan Informatika

Politeknik Negeri Bandung

Bandung, Indonesia

trisna.gelar@polban.ac.id¹, aprianti.nanda@polban.ac.id²

Abstract

Limited competence becomes an obstacle to starting urban farming activities. Practicing instruction on self directed videos on YouTube from individuals and professionals could increase self-competence. However, the quality of instructional videos (content, audio and visuals) varies widely depending on the producers. The audience can directly interact by giving appreciation (positive or negative), responses or questions in the comments sections about the topic being presented. This feedback is useful for creation on frequently asked topics or continuing most liked videos. Comments classification could be done easily using Auto-Keras because the process of selecting models, searching for neural-network architectures and evaluating the best models is done automatically. Research generally consists of four phases, namely (1) collecting datasets, (2) text processing, (3) engineering features, and (4) modeling and evaluation. In this study, 5194 labeled of comments (aspirations, questions, and statements) were collected from 5 popular instructional videos curated by the author based on the highest order of views, likes and dislikes. The quality of commentary sentences is improved in the preparation phase through the process of text cleaning, normalization, tokenization and stemming. In the normalization process, a dictionary of agricultural terms is added so that mixed with similar informal language. Comment sentences are converted to n-gram and word embedding as auto-keras input. The results of model evaluation based on data features, the accuracy of the auto-keras word embedding reached 86.91%, slightly better than auto-keras n-gram with 86.33%.

Keywords: auto-keras, instructional video, classification, YouTube comments, urban farming

Abstrak

Keterbatasan kompetensi menjadi halangan untuk memulai melakukan kegiatan pekarangan perkotaan. Mempraktikkan langkah-langkah pada video instruksional populer di Youtube dari individu maupun profesional dapat meningkatkan kompetensi diri. Namun, kualitas video instruksional(konten, audio dan visual) sangat bervariasi bergantung pada orang yang memproduksinya. Penonton secara langsung dapat berinteraksi dengan memberikan apresiasi (positif maupun negatif), tanggapan atau pertanyaan pada kolom komentar seputar topik yang dipresentasikan. Umpan balik tersebut digunakan untuk memperbaiki kualitas dari video seperti memberikan penjelasan mendalam untuk topik yang sering ditanyakan dan melanjutkan atau menghentikan video berdasarkan topik yang paling disukai atau sebaliknya. Pekerjaan klasifikasi komentar dapat diselesaikan dengan mudah menggunakan Auto-Keras karena proses pemilihan model, pencarian arsitektur *neural network* dan evaluasi model terbaik dilakukan secara otomatis. Penelitian pada umumnya terdiri atas empat fase, yaitu (1) pengumpulan *dataset*, (2) *text processing*, (3) *feature engineering*, dan (4) pemodelan dan evaluasi. Pada penelitian ini telah terkumpul 5194 komentar berlabel(aspirasi, pertanyaan, dan pernyataan) dari 5 video instruksional populer bertemakan pekarangan kota yang dikurasi oleh penulis berdasarkan urutan *views*, *likes* dan *dislikes* tertinggi. Kualitas kalimat komentar diperbaiki pada fase persiapan melalui proses *text cleaning*, *normalization*, *tokenization* dan *stemming*. Pada proses *normalization*, kamus istilah pertanian menjadi informasi agar tidak tercampur dengan bahasa informal yang mirip. Kalimat komentar yang telah normal dikonversikan menjadi *n-gram* dan *word embedding* sebagai input auto-keras. Dari hasil pengujian evaluasi model, akurasi yang dihasilkan *auto-keras* dengan fitur *word embedding* mencapai 86.91% sedikit lebih baik dari akurasi fitur *n-gram* 86.33%.

Kata kunci: auto-keras, komentar Youtube, klasifikasi, pekarangan perkotaan, video instruksional

1. Pendahuluan

Pekarangan perkotaan merupakan upaya peningkatan ketersediaan pangan yang dilakukan oleh penduduk kota dengan memanfaatkan lahan yang ada, seperti pekarangan (sempit, sedang dan luas), fasilitas umum dan ruang terbuka hijau. Pertanian kota mengurangi ketergantungan pada hasil pertanian daerah lain, meningkatkan pendapatan penduduk, serta mendukung upaya kelestarian alam[1]. Kegiatan pertanian kota telah diadopsi dan dilaksanakan di Indonesia, berbagai tanaman dibudidayakan contohnya sayuran, buah-buahan, dan obat

keluarga(toga). Selain itu teknik tanam-menanam populer telah dipraktikkan oleh penggiat tani kota antara lain penggunaan *polybag*, sistem hidroponik, dan akuaponik[2].

Masyarakat kota memiliki atensi tinggi untuk memulai pekarangan perkotaan, namun tidak mudah untuk memulai kegiatan ini karena keterbatasan kompetensi yang dimiliki. Salah satu solusi media pembelajaran bagi pemula untuk memulai sesuatu atau menambah kompetensi adalah mengikuti langkah-langkah dari video instruksional pada platform berbagi video seperti Youtube. Menurut survei 7 dari 10 pemirsa menggunakan Youtube untuk membantu menyelesaikan masalah sehari-hari seperti pekerjaan, belajar ataupun hobi[3]. Kualitas karakter fisik dari video di Youtube berbeda-beda dari segi penyampaian materi, presentasi, dan audio maupun visual video bergantung pada kompetensi dari penggarap konten[4]. Hal tersebut menyebabkan video menjadi populer dan mendapatkan perhatian yang lebih dari penonton. Konten video populer direkomendasikan oleh algoritma pada platform Youtube dan dijadikan prioritas pencarian. Menurut studi, popularitas video didapat dari data frekuensi statistik dasar seperti *likes*(suka), *dislikes*(tidak suka), *shares*(dibagi) dan *views*(dilihat) yang diperoleh melalui data terbuka[5][6] dan interaksi langsung pada kolom komentar[7].

Beberapa peneliti telah mengkaji pemanfaatan video instruksional sebagai media pembelajaran di dalam lingkungan sekolah pada domain bahasa asing. *Olasina* melakukan studi perilaku siswa pada materi menulis akademis berbahasa Inggris menggunakan video dari Youtube, ditemukan bahwa kemampuan siswa meningkat secara kuantitatif (naiknya nilai ujian) maupun kualitatif (mendapatkan pengalaman belajar yang positif seperti selalu merasa penasaran dan belajar seolah-olah bermain[8]. *Oliver* melakukan penelitian pemanfaatan video instruksional berdurasi pendek produksi sendiri sebagai suplemen tambahan pembelajaran bahasa Afrika level universitas bagi mahasiswa asing, peneliti menemukan korelasi perilaku positif dari kegiatan tersebut, siswa menikmati proses kreasi pembuatan video[9].

Dalam domain pekarangan perkotaan, video instruksional diproduksi oleh individu, maupun komunitas penggiat tema tersebut, bukan seorang guru maupun dosen dalam lingkungan tertutup(sekolah/universitas) sebagaimana siswa memiliki dasar pengetahuan yang diperoleh dari kurikulum berkelanjutan. Profil penonton dan produser video pekarangan perkotaan sangat bervariasi. Kemungkinan tidak memiliki pengetahuan dasar baik teori maupun praktik sebelumnya, baru belajar secara otodidak, atau sudah memiliki pengalaman dalam bercocok tanam namun ingin mencoba teknik baru. Perilaku penonton ini dapat digali melalui interaksi mereka pada kolom komentar.

Data komentar merupakan bahan penelitian yang mendapatkan perhatian saat ini. Dalam domain video pariwisata, interaksi pada kolom komentar digali untuk pengelompokan komunitas virtual yang memasarkan kawasan turisme[10]. Selain itu, pengiklan melakukan penargetan konsumen produk (makanan, minuman dan mainan) untuk anak-anak[11]. Dalam studi kasus penelitian ini komentar digali untuk mengklasifikasikan interaksi yang meliputi apresiasi (positif maupun negatif), pertanyaan dan pernyataan seputar topik yang dipresentasikan. Hal ini dapat berguna untuk pembuat video melihat atensi atas videonya atau menentukan tema video lanjutan berdasarkan topik-topik sering ditanyakan.



Gambar 1 Fase AutoML

Automated Machine Learning (AutoML) memungkinkan seseorang yang tidak memiliki latar belakang keilmuan dasar *machine learning* dapat menyelesaikan pekerjaan klasifikasi data dengan mudah. Karena proses pemilihan model, optimasi hiperparameter dan evaluasi model yang rumit dilakukan secara otomatis dengan baik oleh sistem[12]. *Auto-Keras* merupakan framework *AutoML* untuk *deep learning*, proses pembangunan model menggunakan algoritma *neural architecture search* (NAS) berbasis *network morphism* yang akan mencari semua kemungkinan arsitektur *neural network* terbaik yang dapat disusun secara efisien tanpa memerlukan proses pelatihan dari awal. Karena *network morphism*, melakukan modifikasi struktur arsitektur *neural network* eksisting dan mempertahankan fungsi dari arsitektur tersebut. Analog dengan proses yang terjadi pada *AutoML*, terdapat strategi evaluasi model yang dapat menghasilkan nilai objektif untuk model sesuai dengan *dataset* yang diberikan[13].

Penelitian ini mencoba untuk mengklasifikasikan interaksi pada kolom komentar dari video instruksional populer bertema pekarangan perkotaan menggunakan *auto-keras*.

2. Metode Penelitian

Metode kuantitatif digunakan pada penelitian ini, Akurasi model klasifikasi pada komentar video (kalimat apresiasi, kalimat pertanyaan, & kalimat pernyataan) dari *Auto-Keras* akan diukur secara empiris. Gambar 2 merupakan ikhtisar tahapan penelitian, diadopsi dari fase *AutoML*[13], yaitu pengumpulan data, persiapan data, *feature engineering*, dan pembentukan serta evaluasi model dengan *auto-keras*.



Gambar 2 Tahapan penelitian

A. *Pengumpulan Dataset Komentar Video Instruksional Populer Pekanbaru Kota*

Fase pengumpulan dataset terdiri atas empat kegiatan, yaitu (1) menentukan kata-kata kunci kegiatan pekanrangan kota berbahasa Indonesia, (2) mengumpulkan video-video berdasarkan kata kunci dalam *playlist Youtube*, (3) Memilih lima video populer berdasarkan urutan statistik dasar dari *metadata* video menggunakan Youtube Data API, (4) Mengambil komentar-komentar dari video populer dan pelabelan data.

B. *Data Preparation*

Fase persiapan data bertujuan untuk meningkatkan kualitas kalimat terdiri atas empat langkah pemrosesan teks yaitu (1) *text cleaning*, menyeragamkan kata atau kalimat menjadi berhuruf besar atau berhuruf kecil saja dan membersihkan kalimat dari huruf berganda dan tanda baca, (2) *tokenization*, memecah kalimat menjadi kata, frasa, simbol atau elemen lain, hasil akhir biasa disebut *token* (3) *normalization*, mengformalkan *token* menjadi bahasa yang dikenal oleh kamus bahasa Indonesia, kamus istilah pergaulan dan kampus istilah pertanian[14], (4) *stemming*, mengubah *token* ke bentuk dasar dan mengurangi kosa kata karena terdapat proses penggabungan kata.

C. *Feature Engineering*

Fase feature engineering bertujuan untuk mentransformasikan kata-kata agar dapat diolah sebagai data masukan yang dimengerti mesin. Pada penelitian ini terdapat dua fitur kalimat yang digunakan yaitu *n-gram* dan *word embedding*.

N-Gram merupakan *n-token* kombinasi kata; *2-gram (bigram)* adalah kombinasi dua *token* kata seperti selamat siang, siang hari atau hari minggu; *3-gram (trigram)* adalah kombinasi tiga *token* kata seperti maaf mau tanya, mau tanya tentang, atau boleh tanya tentang. Model *N-Gram* menghitung kemungkinan munculnya *n-token* kombinasi pada sebuah kalimat berdasarkan urutan *n-1 token* kata sebelumnya. Pada kasus klasifikasi bentuk model *bigram* lebih baik dari model *1-gram bag-of-words*[15].

Word embedding merupakan pembentukan fitur kata yang berdasarkan pemetaan tiap kata pada kumpulan kosa kata dari korpus yang direpresentasikan menjadi vektor *N-dimensi* bilangan real. Kata-kata bermakna sama memiliki representasi vektor yang serupa. Proses pembelajaran representasi vektor kata dapat disisipkan saat pembentukan model *neural network* atau menggunakan statistik dokumen. Beberapa ragam metode *word embedding* telah diusulkan untuk menerjemahkan *unigrams* menjadi representasi vektor misalnya, *Embedding Layer*, *Word2Vec*, dan *Glove*[15].

D. *Auto-Keras*

Fase *Auto-Keras* bertujuan untuk melakukan proses *Model Selection dan Model Evaluation* secara otomatis untuk mendapatkan arsitektur *neural network* terbaik.

Neural Architecture Search (NAS) merupakan proses pemilihan model secara otomatis dengan mencari semua kemungkinan arsitektur *neural network* terbaik yang dapat disusun pada *pipeline* *Auto-ML* yang berbasis *deep learning*. *Auto-Keras* secara efisien melakukan pencarian arsitektur jaringan saraf tiruan menggunakan konsep *Network Morphism* sebuah pendekatan performansi tinggi, pencarian arsitektur terbaik berdasarkan bobot dari arsitektur yang telah di latih sebelumnya. Pendekatan ini memungkinkan modifikasi arsitektur tanpa merubah fungsi yang ada pada *network*. Hal ini memungkinkan peningkatan kapasitas terus menerus dan mempertahankan performa tinggi tanpa memerlukan proses pelatihan *neural network* tiruan dari awal.[12].

Network Morphism pada *auto-keras* berdasarkan pada algoritma optimasi *bayesian* yang terdiri dari tiga tahap yaitu (1) *Update*: melatih proses gaussian yang mendasari penentuan model berdasarkan arsitektur awal dan ukuran performansinya. (2) *Generation*: membangkitkan arsitektur berikutnya untuk diamati dengan mengoptimalkan fungsi akuisisi yang terdefinisi secara cermat. (3). *Observation*: memperoleh nilai performansi aktual berdasarkan hasil latih dari arsitektur *neural network* yang telah dibangun.[12].

Terdapat enam alur kerja pemodelan dengan *auto-keras* yaitu (1) Pengguna menginisiasi pencarian arsitektur *neural network* terbaik untuk *dataset*-nya (2). API menerima panggilan tersebut, melakukan proses *pre-processing* dan mengirim data ke *Searcher*, Operator optimasi *Bayesian* akan membangun arsitektur baru menggunakan CPU (3). Modul Graf meneruskan arsitektur *neural network* ke RAM untuk diproses secara langsung. (4) Lalu arsitektur *neural network* di salin ke GPU untuk pelatihan model. (5) Model latih disimpan ke dalam *Hard Drive*. (6) Performansi model digunakan sebagai upan balik untuk *Searcher* dengan memperbaharui nilai pada proses gaussian berdasarkan algoritma optimasi bayesian. [12].

3. Hasil dan Pembahasan

A. *Pengumpulan Dataset Komentar Video Instruksional Populer Pekarangan Kota* terdiri atas empat kegiatan yaitu:

1). Menentukan kata kunci kegiatan pekarangan kota berbahasa Indonesia.

Kata kunci diperoleh dari dua topik yang berhubungan dengan pekarangan kota yaitu kompetensi dan teknik bertanam. Tiga kata kunci kompetensi bertanam dipilih berdasarkan SKKNI 2015-460 tentang bidang produksi dan produktivitas tanaman yaitu kompetensi menanam(menetapkan komoditas, menyiapkan lahan dan melakukan pengelolaan tanaman), kompetensi memelihara(pemupukan, perawatan, pengendalian hama), dan kompetensi memanen(pengelolaan panen dan pengumpulan hasil panen)[16]. Teknik menanam di polybag terpilih sebagai kata kunci, karena kompatibel dengan keadaan pekarangan di daerah perkotaan yang umumnya sempit, praktis mudah didapatkan, terjangkau dan mudah dipelajari.

2). Mengumpulkan video-video kedalam playlist Youtube

Tabel 1 merupakan kurasi video-video instruksional yang diupload dua tahun terakhir (2019-2020) dengan kata kunci menanam, memelihara, memanen dan polybag yang dikumpulkan dan disaring ke Playlist Youtube secara manual.

Tabel 1 Kurasi Video Pekarangan Kota

No	Keyword	Playlist	Total Video
1	menanam polybag	Urban Farming Bahasa Indonesia : Menanam	205
2	memelihara polybag	Urban Farming Bahasa Indonesia : Memelihara	113
3	memanen polybag	Urban Farming Bahasa Indonesia : Menanam	43

3). Memilih lima video populer

Pada kegiatan ini lima video paling populer dipilih berdasarkan statistik metadata dasar pada tiga playlist yang telah dikurasi. Metadata yang dijadikan acuan meliputi jumlah *views*(tayang), *likes*(suka), *dislikes*(tidak suka) dan *comments*(komentar) pada tiap video diperoleh menggunakan parameter *statistics* pada Youtube Data API melalui API untuk bahasa python *google-api-python-client*. Tabel 2 mendeskripsikan statistik dasar video-video populer pekarangan kota.

Tabel 2 Lima Video Populer Pekarangan Kota

No	ID Video	View	Likes	Dislikes	Comments
1	Se6NI8vkl6k	7533918	68000	4100	5051
2	SepEHkCNOu0	5957853	33000	4600	1459
3	MSIDgA9XxJM	3773064	31000	2300	2681
4	n9w0HWMwYNA	1713018	12000	1100	367
5	rgFZfTaNOmY	1651271	17000	1200	1576

4). Mengambil komentar-komentar dari video populer dan pelabelan data.

Pada kegiatan ini lima video populer diekstraksi tiap komentarnya melalui parameter *commentThreads* pada *Youtube Data API*, komentar yang didapat adalah komentar utama bukan diskusi yang rekursif. Setelah itu komentar diobservasi dan disaring sesuai dengan kategori kalimat apresiasi, pertanyaan dan pernyataan. Kalimat komentar berbahasa daerah tidak diproses sebagai dataset.

Kalimat apresiasi, berhubungan dengan pengertian, penghargaan, kepekaan pikiran, perasaan, kritis terhadap karya seseorang. Kalimat pertanyaan, berintonasi interogatif dan dari segi makna mengandung kata tanya dan dari segi ejaan di beri tanda tanya. Kalimat pernyataan atau kalimat berita, berintonasi deklaratif dan dari segi makna mengandung pemberitahuan untuk khalayak[17].

Ketiga kategori kalimat pada komentar Youtube, secara observasi mengabaikan aturan ejaan bahasa Indonesia seperti tidak memiliki tanda tanya(?), titik(.) dan koma(.). Menggunakan bahasa informal, bahasa daerah, singkatan prokem, dan gemar melakukan duplikasi huruf pada kata.

Pelabelan data dilakukan oleh penulis satu dan dua untuk setiap komentar pada video, tiap kalimat memiliki satu label. Apabila terdapat perbedaan pelabelan antara penulis, kalimat tersebut tidak dimasukkan kedalam dataset.

Table 3 Komentar Tersaring pada Video Populer

No	ID Video	Komentar	
		Raw	Filter
1	Se6N18vkl6k	5051	2291
2	SepEHkCNOu0	1459	427
3	MSIDgA9XxJM	2681	1450
4	n9w0HWMwYNA	367	280
5	rgFZfTaNOmY	1576	749

Tabel 3 mendeskripsikan komentar tersaring pada lima video populer, khusus video ke-2 banyak komentar dibuang karena diluar konteks dari kategori yang didefinisikan.

Tabel 4 mendeskripsikan jumlah kategori pada dataset komentar video populer dan contoh kalimat.

Tabel 4 Distribusi Kategori pada Komentar Video Populer

Komentar	apresiasi	pertanyaan	pernyataan	Total
	1660	2705	829	
Contoh Kalimat	Assalamualaikum. Masyaallah semoga ilmu nya berkah... Terimakasih kak atas ilmu nya.	Pak, bisakah daun ketumbar ditnm didaerah Jakarta ? Mohon petunjuknya, terima kasih.:	media tanam yang kita gunakan dari bahan blotong dan arang sekam dengan perbandingan 2 blotong + 1 arang sekam. blotong adalah limbah dari nira tebbu.	5194

B. Data Preparation

Pada fase ini kalimat komentar diperbaiki kualitasnya, melalui pemrosesan kalimat secara bertahap meliputi *text cleaning*, *normalization*, *stemming* dan *tokenization* yang dilakukan terprogram menggunakan library pada python setelah itu secara manual dipilah lagi apabila kalimat tidak sesuai kelas yang diinginkan seperti jumlah kata, konteks kalimat merupakan spam dan tidak mengandung arti. Tabel 5 mengilustrasikan perubahan yang terjadi pada proses-proses persiapan data.

Tabel 5 Perubahan kalimat komentar melalui Data Preparation

No	Proses	Kalimat
1	Inisiasi	Pak, bisakah daun ketumbar ditnm didaerah Jakarta ? Mohon petunjuknya, terima kasih.:
2	<i>Text Cleaning</i>	pak bisakah daun ketumbar ditnm didaerah jakarta mohon petunjuknya terima kasih
3	<i>Normalization</i>	pak bisakah daun ketumbar ditanam di daerah jakarta mohon petunjuknya terima kasih
4	<i>Stemming</i>	pak bisa daun ketumbar tanam di daerah jakarta mohon tunjuk terima kasih
5	<i>Tokenization</i>	['pak', 'bisa', 'daun', 'ketumbar', 'tanam', 'di', 'daerah', 'jakarta', 'mohon', 'tunjuk', 'terima', 'kasih']

1). Text Cleaning

Pada langkah teks cleaning, kalimat dibersihkan dari tanda baca, huruf berganda yang biasanya terdapat pada kata ekspresif (segerrrr, mantapp, boss) menggunakan fungsi regular expression pada python, dan merubah huruf kapital menjadi huruf kecil.

2). Normalization

Pada langkah teks normalization kata-kata nonformal di normalisasi menggunakan kosa kata dari kamus alay[18] dan istilah pertanian[14]. Kamus merupakan file text berekstensi csv dengan dua kolom, kata informal dengan padanan kata normalnya. Setiap kata pada kalimat komentar diperiksa padanan katanya apakah ada di dalam kamus tersebut. Untuk mempercepat pencarian index kata kamus pada penelitian ini dibantu dengan

library flashtext[19]. Pada ilustrasi tabel 5 proses no 3, kata **ditnm** di ubah menjadi **ditanam** berdasarkan kamus pertanian.

3). Stemming

Pada langkah teks stemming kalimat komentar yang telah dinormaliasi diubah bentuk katanya menjadi kata dasar menggunakan fungsi *Sastrawi.Stemmer.StemmerFactory* pada library Sastrawi. Pada penelitian ini proses penghapusan stopwords tidak digunakan karena secara observasi pada kalimat pertanyaan didataset terdapat kata modalitas suatu cara pembicara menyatakan suatu keadaan dan situasi informal. Terdapat 3 kata modalitas tercatat yaitu ijin (boleh, tidak mengapa), tanya(siapa, berapa, di mana), kesangsian (mungkin, agaknya, barangkali).

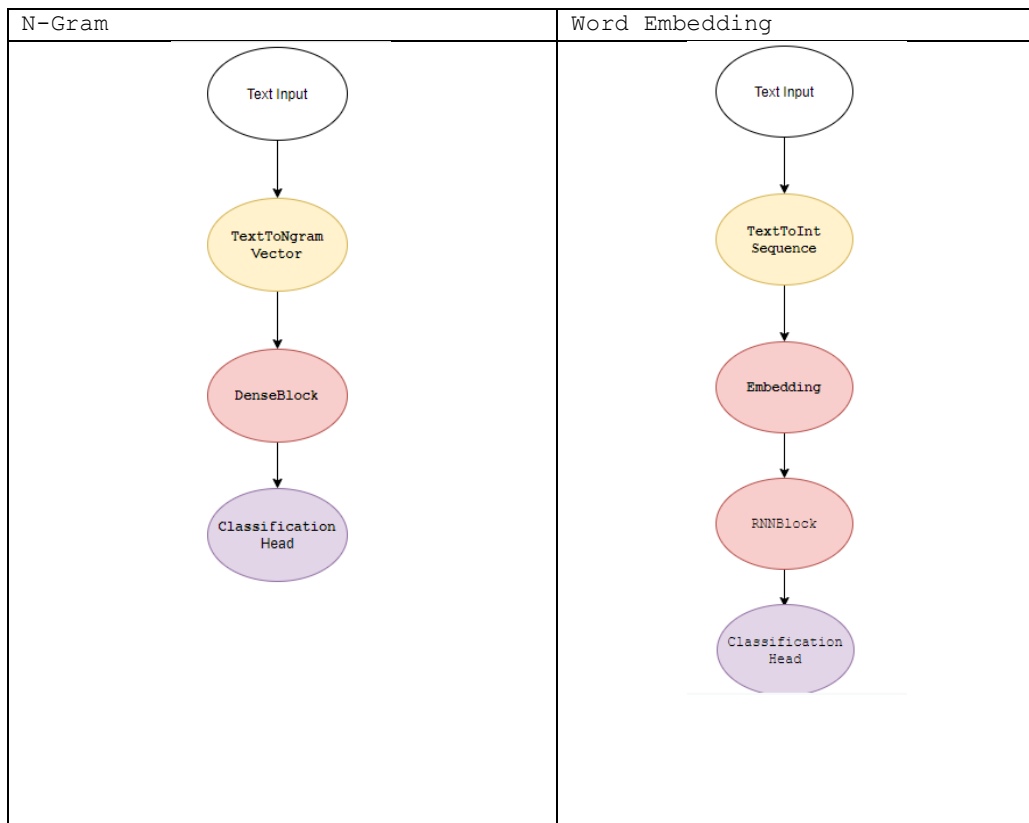
4). Tokenization

Pada langkah tokenisasi kalimat komentar yang sudah destemming dipecah menjadi kata atau biasa disebut token, menggunakan fungsi *nlk.tokenize* dari bantuan library *nlk*. Token ini akan ditransformasi menjadi n-gram maupun word embedding.

C. Auto-Keras

Selain proses Seleksi Model, Neural Architecture Search (NAS) dan Evaluasi Model secara otomatis, transformasi kata menjadi n-gram dan word embedding merupakan bagian dari fitur auto-keras selain itu proses tersebut disisipkan kedalam arsitektur *neural network*. Layer *TextToNgramVector* dan Layer *DNN* digunakan untuk membangun n-gram sedangkan Layer *Embedding* dan Layer *RNN* untuk word embedding. Tabel 5 mendeskripsikan building block pembangunan model menggunakan auto-keras berdasarkan teknik rekayasa fiturnya.

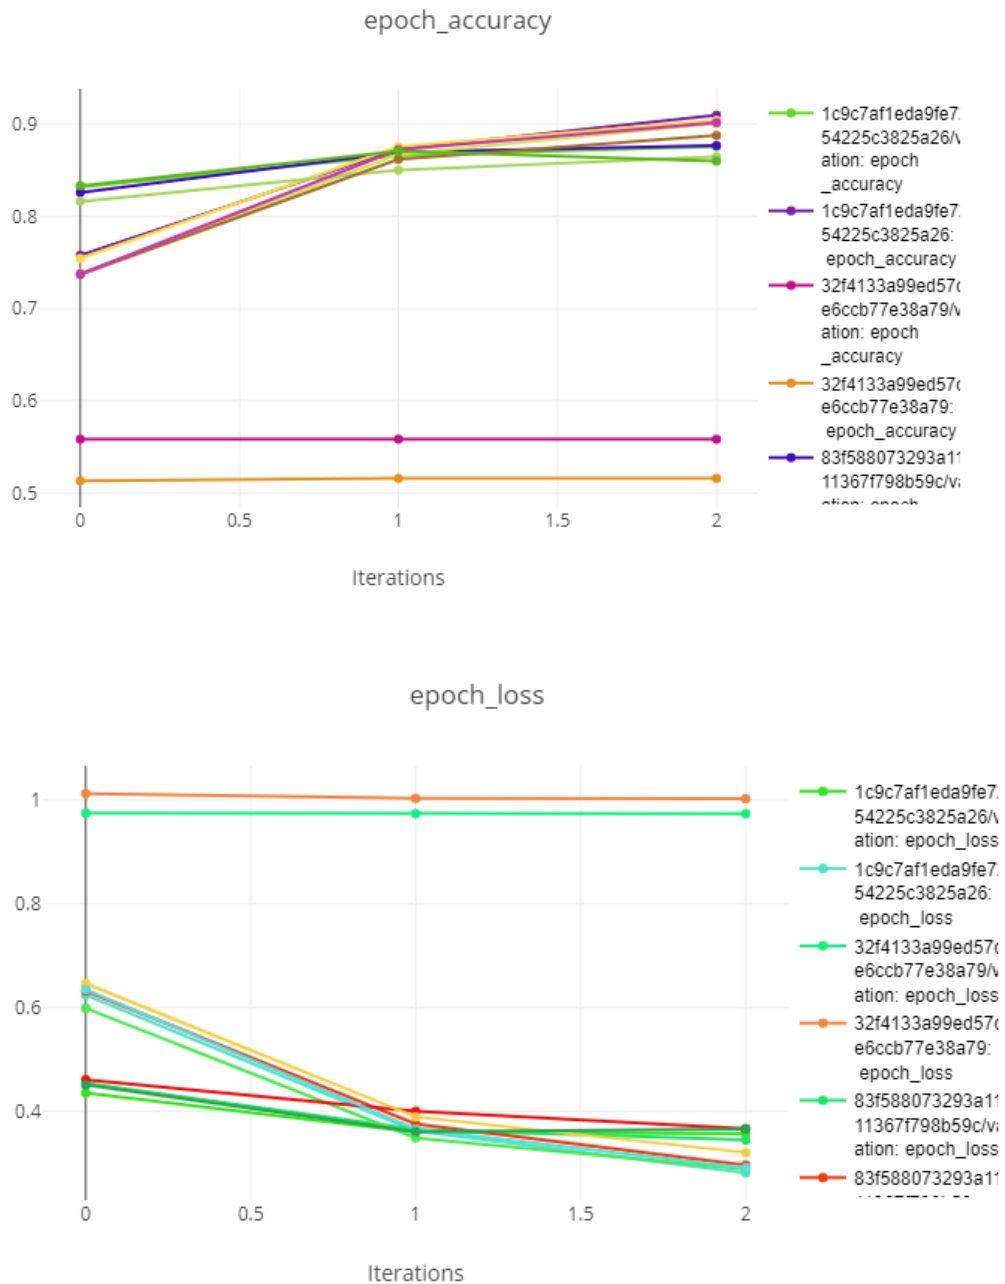
Tabel 5 Perbandingan prosedur pembangunan model di *Auto-Keras*[20]



1). Perbandingan Hasil Evaluasi Model Auto Keras N-Gram


Gambar 3 mengilustrasikan hasil evaluasi model auto-keras dengan layer n-gram, auto-keras secara otomatis membangun beberapa arsitektur neural network dan dievaluasi menggunakan pengukuran *accuracy*. Grafik *epoch_accuracy* dan *epoch_loss* merupakan ikhtisar dari pengukuran tersebut, *epoch accuracy* merupakan *accuracy* model sedangkan *epoch loss* merupakan hasil dari *loss function* yang digunakan untuk mengupdate parameter saat proses training. Best Model memiliki *epoch_accuracy* 0.940 dan *epoch_loss*

sebesar 0.228 sedangkan Worst Model memiliki epoch_accuracy sebesar 0.513 dan epoch_loss sebesar 0.981 hal ini merupakan anomali, karena model lain mendekati ukuran performansi model terbaik atau disebut Best Model yaitu model yang memiliki nilai accuracy tertinggi dan loss terendah selain itu arsitektur *neural network* yang dipilih secara otomatis berdasarkan perhitungan optimasi bayesian terbaik pada fase *network morphism*.



Gambar 3 Hasil Evaluasi Model Auto-Keras N-Gram

Gambar 4 mengilustrasikan hasil evaluasi model auto-keras dengan layer word embedding, Best Model memiliki epoch_accuracy 0.921 dan epoch_loss sebesar 0.260 sedangkan Worst Model memiliki epoch_accuracy sebesar 0.854 dan epoch_loss sebesar 0.482 mendekati nilai Best Model. Dibandingkan n-gram, model word embedding menghasilkan arsitektur *neural network* yang konsisten akurasinya.



Gambar 4 Hasil Evaluasi Model Auto-Keras Word Embedding

2). Perbandingan Best Model untuk tipe fitur N-Gram dan Word Embedding

```

InputLayer [(None,)]
TensorFlowOpLayer (None, 1)
TextVectorization (None, 500)
    Dense (None, 32)
    ReLU (None, 32)
    Dense (None, 32)
    ReLU (None, 32)
    Dense (None, 3)
    Softmax (None, 3)
Total params: 2,402,303
Trainable params: 2,402,303
Non-trainable params: 0
    Best Model N-Gram
    
```

```

InputLayer [(None,)]
TensorFlowOpLayer (None, 1)
TextVectorization (None, 64)
    Embedding (None, 64, 100)
    Dropout (None, 64, 100)
    Bidirectional (None, 64, 200)
    Bidirectional (None, 200)
    Dense (None, 3)
    Softmax (None, 3)
Total params: 16,631
Trainable params: 16,131
Non-trainable params: 500
    Best Model Word Embedding
    
```

Perbedaan utama layer *neural network* yang dihasilkan dari auto-keras pada model fitur teks n-gram adalah penggunaan *full connected layer* dan *ReLU* sedangkan pada model fitur teks *word embedding* adalah penggunaan *Embedding Layer*, *Dropout Layer* dan *Bidirectional RNN layer*. Selain itu penggunaan *trainable* parameternya lebih sedikit sekitar 16,131 dibandingkan dengan n-gram 2,400,303 parameter.

3). Perbandingan training accuracy, training loss, test accuracy dan test loss Auto-Keras n-gram dan word embedding.

Tabel 6 Perbandingan accuracy dan loss Best Model Auto-Keras n-gram dan word embedding

Model	Training		Testing	
	Acc	Loss	Acc	Loss
Auto-Keras				
Word Embedding	0.940	0.228	0.869	0.41
N-Gram	0.921	0.260	0.863	0.438

Tabel 6 mengilustrasikan perbandingan *accuracy* dan *loss* model pada saat fase training dan testing, dataset secara proporsional 80:20 dibagi untuk training (4155 komentar) dan testing (1039 komentar). Terlihat pada tabel kedua *best model Word Embedding* memiliki nilai *accuracy* dan *loss* yang sedikit lebih baik dibandingkan dengan *N-Gram* untuk kedua fase.

4. Kesimpulan

Hasil dari penelitian ini pembangunan model data menggunakan auto-keras pada dataset komentar video instruksional yang terannotasi serta evaluasinya. Proses persiapan data pada kalimat komentar telah diselesaikan sehingga komentar memiliki kualitas yang baik terkumpul 5194 komentar berlabel (aspirasi, pertanyaan, dan pernyataan) dari 5 video instruksional populer bertemakan pekarangan kota yang dikurasi oleh penulis berdasarkan urutan views, likes dan dislikes tertinggi. Terdapat dua skenario pembangunan model data berdasarkan rekayasa fitur yaitu n-gram dan *word embedding*. Dari hasil evaluasi model, nilai akurasi dan loss pada fase training model word embedding sedikit lebih baik dari n-gram mencapai 86.91% dan 86.33%. Namun secara umum terdapat penurunan nilai *accuracy* dan peningkatan *loss* untuk kedua model, hal ini disebabkan fenomena overfitting data ketika melakukan evaluasi data baru.

Untuk penelitian selanjutnya disarankan untuk memperhatikan usaha-usaha untuk mengurangi gap accuracy model saat fasetraining dan testing yang terjadi karena fenomena *overfitting*. Usaha meliputi percobaan penggunaan layer *Dropout Regularization* atau penambahan fungsi *callback* untuk n-gram dan *web embedding* model *layer*. Selain itu melakukan penambahan data komentar teranotasi pada dataset yang masih berhubungan dengan tema kompetensi atau teknik pekarangan kota yang lain seperti hidroponik, tambulapot dan aquaponik.

5. Ucapan Terima kasih

Program Penelitian Mandiri ini didukung oleh dana Penelitian Mandiri Politeknik Negeri Bandung. Penulis mengucapkan terima kasih atas pendanaan yang telah diberikan.

6. Daftar Rujukan

- [1] A. R. Fauzi, A. N. Ichniarsyah, and H. Agustin, "Pertanian Perkotaan : Urgensi, Peranan, Dan Praktik Terbaik," Jurnal Agroteknologi, vol. 10, no. 01, p. 14, 2016.
- [2] A. Hermawan and IAARD Press, Eds., Kawasan rumah pangan lestari: pekarangan untuk diversifikasi pangan, Cetakan 2014. Jakarta: IAARD Press, Badan Penelitian dan Pengembangan Pertanian, Kementerian Pertanian, 2014.
- [3] C. O'Neil and Hart, "Why you should lean into how-to content in 2018," Dec. 30, 2017. <https://www.thinkwithgoogle.com/marketing-strategies/video/self-directed-learning-youtube/> (accessed Oct. 16, 2020).
- [4] P. Ten Hove and H. van der Meij, "Like It or Not. What Characterizes YouTube's More Popular Instructional Videos?," Society for Technical Communication, vol. 62, no. 1, pp. 48–62, 2015.
- [5] L. A. Liikkanen, "Three Metrics for Measuring User Engagement with Online Media and a YouTube Case Study," p. 4.
- [6] J. S. Morgan, I. Barjasteh, C. Lampe, and H. Radha, "The Entropy of Attention and Popularity in YouTube Videos," p. 18, 2014.
- [7] T. Li, L. Lin, M. Choi, K. Fu, S. Gong, and J. Wang, "YouTube AV 50K: An Annotated Corpus for Comments in Autonomous Vehicles," 2018 International Joint Symposium on Artificial Intelligence and Natural Language Processing (iSAI-NLP), pp. 1–5, Nov. 2018, doi: 10.1109/iSAI-NLP.2018.8692799.
- [8] G. Olasina, "An evaluation of educational values of YouTube videos for academic writing," vol. 9, no. 4, p. 31.
- [9] J. Olivier, "Short Instructional Videos as Multimodal Open Educational Resources in a Language Classroom," p. 29.
- [10] A. Sambhanthan, S. Thelijagoda, and J. Tan, "Implications for utilizing YouTube based community interactions for destination marketing: Investigation of a typology approach," in 2013 8th International Conference on Computer Science & Education, Colombo, Sri Lanka, Apr. 2013, pp. 365–370, doi: 10.1109/ICCSE.2013.6553939.
- [11] C. S. Araujo, G. Magno, W. Meira Jr, V. Almeida, P. Hartung, and D. Doneda, "Characterizing videos, audience and advertising in Youtube channels for kids," arXiv:1707.00971 [cs], Jul. 2017, Accessed: Oct. 18, 2020. [Online]. Available: <http://arxiv.org/abs/1707.00971>.
- [12] H. Jin, Q. Song, and X. Hu, "Auto-Keras: An Efficient Neural Architecture Search System," in Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, Anchorage AK USA, Jul. 2019, pp. 1946–1956, doi: 10.1145/3292500.3330648.
- [13] X. He, K. Zhao, and X. Chu, "AutoML: A Survey of the State-of-the-Art," arXiv:1908.00709 [cs, stat], Jul. 2020, Accessed: Oct. 16, 2020. [Online]. Available: <http://arxiv.org/abs/1908.00709>.
- [14] Liem, J.S., 1984. Kamus istilah pertanian. Pusat Pembinaan dan Pengembangan Bahasa, Departemen Pendidikan dan Kebudayaan.
- [15] Kowsari, Jafari Meimandi, Heidarysafa, Mendu, Barnes, and Brown, "Text Classification Algorithms: A Survey," Information, vol. 10, no. 4, p. 150, Apr. 2019, doi: 10.3390/info10040150.
- [16] Dhakiri. M.H, Penetapan Standar Kompetensi Kerja Nasional Indonesia Kategori Pertanian, Kehutanan Dan Perikanan Golongan Pokok Pertanian Tanaman, Peternakan, Perburuan Dan Kegiatan Yang Berhubungan Dengan Itu(Ybdi) Bidang Produksi Dan Produktivitas Tanaman. 2015.
- [17] Lubis, A.H.H., 1990. Glosarium bahasa dan sastra. Fakultas Keguruan Sastra Seni, Institut Keguruan dan Ilmu Pendidikan.

- [18] N. Aliyah Salsabila, Y. Ardhito Winatmoko, A. Akbar Septiandri, and A. Jamal, "Colloquial Indonesian Lexicon," in 2018 International Conference on Asian Language Processing (IALP), Bandung, Indonesia, Nov. 2018, pp. 226–229, doi: 10.1109/IALP.2018.8629151.
- [19] V. Singh, "Replace or Retrieve Keywords In Documents at Scale," arXiv:1711.00046 [cs], Nov. 2017, Accessed: Oct. 21, 2020. [Online]. Available: <http://arxiv.org/abs/1711.00046>.
- [20] Text Classification, https://autokeras.com/tutorial/text_classification/, Accessed: Oct. 21, 2020.