



Verifikasi Kesesuaian Materi Pembelajaran Menggunakan Model Bidirectional Encoder Representations from Transformers (BERT) dan Semantic Textual Similarity

Riani Saputri Abadi

Sekolah Pasca Sarjana, Magister Ilmu Komputer, Institut Teknologi PLN, Jakarta Barat, Indonesia

Email: ^{1,*}riani@itpln.ac.id

Email Penulis Korespondensi: riani@itpln.ac.id

Submitted: 10/02/2025; Accepted: 25/03/2025; Published: 26/03/2025

Abstrak—Tantangan pada domain pendidikan untuk memastikan pembelajaran dapat terevaluasi secara efektif dan terstruktur sebagai upaya untuk peningkatan dan penguatan kualitas standar pendidikan dalam mencapai pembelajaran yang optimal. Pada penelitian ini dilakukan implementasi untuk evaluasi capaian pembelajaran berbasis Natural Language Processing dengan menggunakan BERT khusus Bahasa Indonesia (IndoBERT) dan Cosine similarity untuk menilai konsistensi dan akurasi materi pembelajaran dengan Berita Acara Kehadiran Perkuliahan (BAKP) dan Rencana Pembelajaran Semester (RPS). IndoBERT digunakan untuk melakukan ekstraksi vektor embedding sebagai representasi semantik kontekstual dari dokumen dan dilakukan perhitungan tingkat kesamaan dengan menggunakan Cosine Similarity antara isi BAKP dengan RPS guna memastikan ketercapaian tujuan pembelajaran. Metodologi penelitian terdiri dari pengumpulan data, pre-processing data, tokenisasi data, dan sentence embedding menggunakan IndoBERT serta perhitungan tingkat kesamaan dan evaluasi performa model. Hasil penelitian menunjukkan bahwa implementasi model IndoBERT menghasilkan tingkat kesamaan yang baik dengan nilai di atas ambang batas yang ditetapkan, yaitu 0,50 dengan hasil cosine similarity 0,674 dan evaluasi performa sebesar 100%. Pendekatan ini dapat memberikan potensi proses otomatisasi proses penjaminan mutu pendidikan tinggi terutama untuk proses evaluasi akademik berdasarkan BAKP dan RPS agar materi pembelajaran selalu relevan *dan up to date* dengan kebutuhan industri.

Kata Kunci: Natural Language Processing; IndoBERT; Cosine Similarity; Berita Acara Kehadiran Perkuliahan; RPS

Abstract—The challenge in the education domain is ensuring that learning can be evaluated effectively and in a structured manner to improve and strengthen the quality of education standards in achieving optimal learning. In this study, an implementation was carried out to evaluate learning outcomes based on Natural Language Processing using BERT (IndoBERT) and Cosine similarity to assess the consistency and accuracy of learning materials with BAKP and RPS. IndoBERT is used to extract embedding vectors as contextual semantic representations from documents, and the similarity level is calculated using Cosine Similarity between the contents of BAKP and RPS to ensure the achievement of learning objectives. The research methodology consists of data collection, pre-processing, tokenization, and sentence embedding using IndoBERT, calculating the similarity level, and evaluating model performance. The results showed that implementing the IndoBERT model produced a good level of similarity with a value above the threshold, which was 0.50, with a Cosine Similarity result of 0.674 and a performance evaluation of 100%. This approach can provide the potential for automation of the higher education quality assurance process for academic evaluation based on BAKP and RPS so that learning materials are always relevant and updated with industry needs.

Keywords: Natural Language Processing; IndoBERT; Cosine Similarity; Lecture Attendance Report; Semester Learning Plan

1. PENDAHULUAN

Akselerasi signifikan pada sektor pendidikan tinggi terutama menjawab tantangan transformasi digital menunjukkan adanya pertumbuhan adopsi teknologi pembelajaran di tahun 2023 [1]. Perubahan ini menjadikan sebuah tantangan yang substansial di era Revolusi Industri 4.0 dalam upaya memastikan kesesuaian proses pembelajaran selalu relevan dan up to date dengan kebutuhan industri yang dinamis [2]. Berdasarkan laporan World Economic Forum 2024, terdapat indikasi kesenjangan antara kebutuhan di dunia kerja dengan materi pembelajaran yang disampaikan di perguruan tinggi [3]. Salah satu bentuk upaya strategis untuk peningkatan dan penguatan kualitas standar pendidikan dalam menjembatani kesenjangan tersebut serta demi mencapai pembelajaran yang optimal adalah melalui evaluasi pembelajaran pada aspek non akademis, seperti kehadiran mahasiswa dalam pertemuan perkuliahan, dimana tingkat kehadiran yang baik cenderung berkorelasi positif dengan pencapaian hasil belajar yang optimal serta aspek akademis sesuai standar Indikator Kinerja Utama (IKU) yang diatur oleh Kemendikbudristek [4].

Implementasi IKU 7 yang menekankan pada evaluasi pembelajaran yang menjadi aspek krusial pada perguruan tinggi dalam memastikan efektivitas dan kualitas proses pendidikan yang diselenggarakan, termasuk pada prodi Teknik Informatika Institut Teknologi Perusahaan Listrik Negara (ITPLN). Salah satu aspek penting untuk mencapai target IKU 7 adalah memastikan kesesuaian Berita Acara Kehadiran Perkuliahan (BAKP) [5] dengan Rencana Pembelajaran Semester (RPS) [6] berdasarkan standar kurikulum nasional dan internasional [7]. Namun, dalam praktiknya proses verifikasi kesesuaian BAKP dengan RPS terstandarisasi menjadi tantangan utama bagi program studi, terutama di perguruan tinggi swasta yang memiliki keterbatasan sumber daya. Banyak kampus swasta, termasuk ITPLN proses verifikasi ini masih dilakukan secara manual, dimana hal tersebut banyak memakan waktu serta tenaga yang besar, juga rentan kesalahan terhadap inkonsistensi dan bias subjektif. Hal ini menjadi tentunya berdampak kepada tingkat efektivitas serta akurasi hasil verifikasi tersebut.

Secara global, perkembangan teknologi terutama di bidang Artificial Intelligence, khususnya untuk domain Natural Language Processing (NLP) membuka peluang pada dunia pendidikan tinggi dengan menggunakan beberapa



macam pendekatan NLP untuk meningkatkan efektivitas dan akurasi proses verifikasi materi pembelajaran. Salah satu model yang dapat diimplementasikan pada proses tersebut adalah model BERT (*Bidirectional Encoder Representations from Transformers*) yang dapat memahami konteks kata dalam kalimat maupun paragraf [8] yang telah menunjukkan hasil yang menjanjikan dalam menghitung tingkat kemiripan kata dalam Bahasa Mandarin/Cina dengan menggunakan Korelasi Pearson dihasilkan rerata 0,7578 [9] dan pada implementasi dalam analisis konten pembelajaran dengan menggunakan Quora dataset didapatkan tingkat akurasi sebesar 91% [10].

Beberapa penelitian terkini lainnya juga didapatkan hasil yang menunjukkan tingkat efektivitas yang baik untuk analisis konten pembelajaran, seperti yang dilakukan oleh Whalley dengan menggunakan BERT untuk pemetaan materi pembelajaran terhadap kurikulum dengan menggunakan dataset universitas di Inggris dihasilkan akurasi sebesar 91% [11]. Selanjutnya dengan mengombinasikan BERT dengan *Adaptive Learning Systems* untuk penyesuaian otomatis materi pembelajaran berdasarkan *style* belajar siswa menghasilkan akurasi 88,7% yang jauh lebih tinggi dibandingkan dengan model berbasis rule-based sebesar 72,5% [12]. Penelitian juga dilakukan pada pengembangan keterampilan berbasis analisis semantik dengan menggunakan BERT untuk mengukur keterkaitan bahan ajar dosen dengan referensi akademik dicatatkan peningkatan akurasi STS mencapai 93,2% lebih baik dari pada pendekatan berbasis Word2Vec dimana akurasi hanya sebesar 81,5% [13]. Eksplorasi penerapan model berbasis transformer untuk sistem evaluasi otomatis terhadap jawaban subjektif dengan mengombinasikan BERT dan Cosine Similarity pada eksperimen jawaban siswa dengan jawaban referensi dihasilkan akurasi hingga 92,4% dengan nilai F1-Score 89%, hasil ini lebih baik daripada menggunakan pendekatan berbasis TF-IDF dan LSA yang hanya mencapai tingkat akurasi 76,3% dan 81,7% untuk masing-masing model secara berturut-turut [14]. Akan tetapi, implementasi yang serupa untuk konten pembelajaran dalam Bahasa Indonesia masih terbatas sehingga menciptakan gap penelitian yang memerlukan eksplorasi lebih lanjut. Penggunaan BERT yang dikombinasikan dengan teknik Semantic Textual Similarity (STS) yang memungkinkan untuk dilakukan pengukuran tingkat kesamaan makna diantara dua teks yang berbeda dengan melakukan perbandingan BAKP dengan RPS [15]. Kombinasi metode ini menawarkan potensi yang besar dalam meningkatkan efektivitas dan akurasi proses verifikasi kesesuaian Berita Acara Kehadiran Perkuliahan (BAKP) dengan Rencana Pembelajaran Semester (RPS).

2. METODOLOGI PENELITIAN

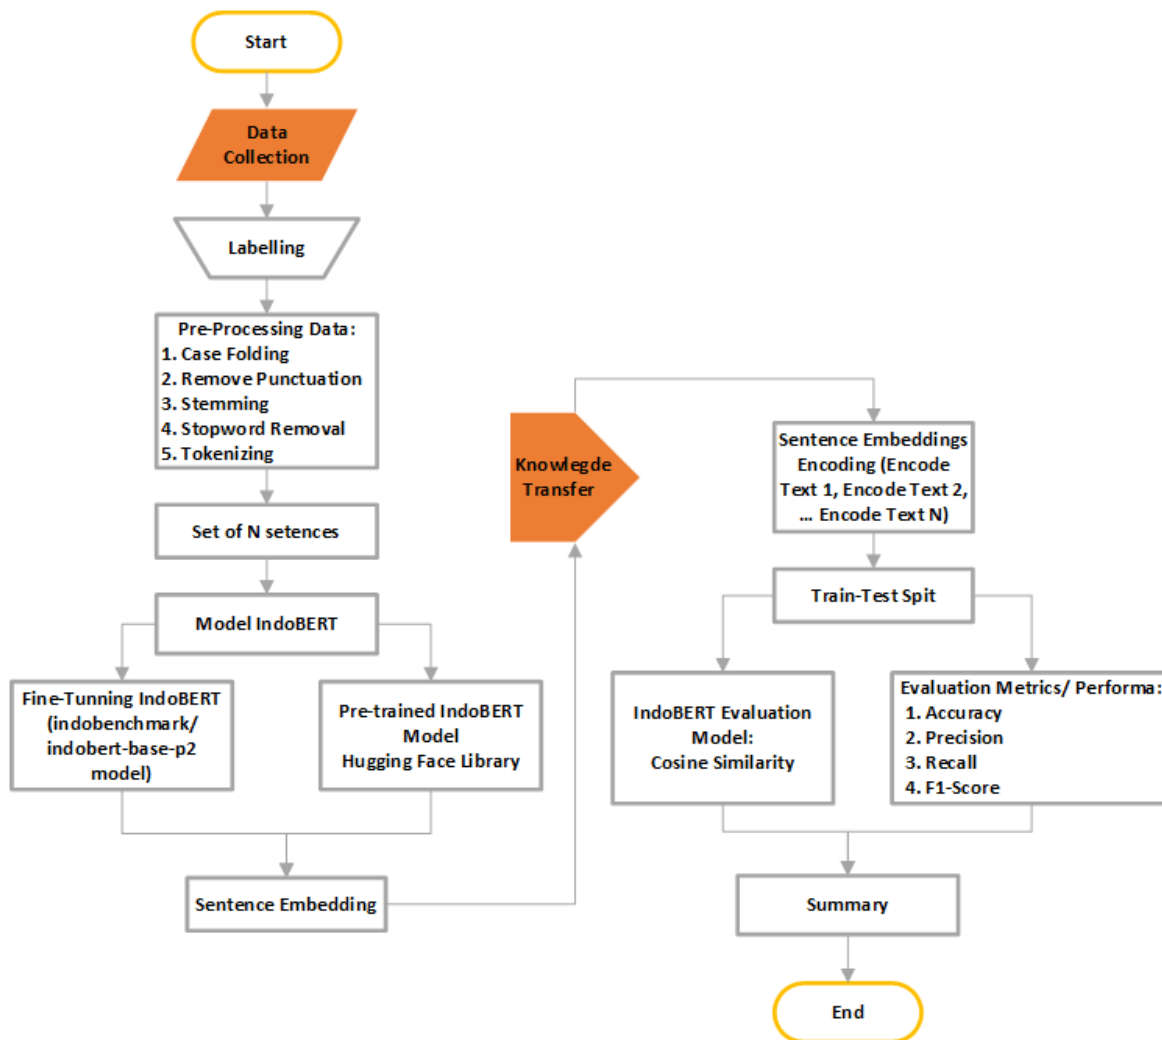
2.1 Tahapan Penelitian

Metode Penelitian yang digunakan adalah metode berdasarkan model transformer BERT dan teknik STS. Tahapan penelitian ini memiliki beberapa tahap diantaranya, yaitu pengumpulan dataset, dilanjutkan dengan labelling untuk menentukan dataset yang dipakai untuk proses model secara manual dengan memisahkan berdasarkan semester mata kuliah pada kurikulum, *pre-processing data*, implementasi model IndoBERT dengan menggunakan *library Hugging Face* dengan model *indobert-base-p2*, proses *sentence embedding*, *encoding*, *train-test split*, kemudian evaluasi model dengan menggunakan Cosine Similarity dan *evaluation metrics* dengan *Accuracy*, *Precision*, *Recall*, dan *F1-Score* serta kesimpulan seperti terlihat pada Gambar 1.

Pada tahap awal dilakukan pengumpulan dataset yang akan digunakan dalam penelitian, seperti BAKP dan RPS yang mengacu kepada SN-Dikti (Standar Nasional Pendidikan Tinggi), kemudian dilanjutkan dengan proses labelling dataset dengan melakukan pengelompokan data secara manual, pemisahan ini berdasarkan pada semester mata kuliah sesuai dengan kurikulum yang berlaku dan memberikan label yang sesuai untuk setiap kategorinya, berdasarkan semester. Proses dilanjutkan dengan *pre-processing data* untuk proses normalisasi teks agar data yang akan diproses oleh model memiliki standar yang sama, yaitu dengan mengubah format untuk huruf diubah menjadi *lowercase* pada fungsi *Case Folding*, *Remove punctuation* untuk menghilangkan atau penghapusan tanda baca, *Stemming* berfungsi untuk mengubah menjadi kata dasar serta *stopword removal* untuk penghapusan kata tidak penting [16] dan *tokenizing* yang merupakan fungsi fundamental dengan memecah teks menjadi unit-unit kata atau token sehingga memungkinkan model dapat memproses sesuai dengan teknik algoritmanya dikarenakan model tidak dapat memproses teks mentah secara langsung.

Pada tahap berikutnya adalah implementasi model IndoBERT dengan memanfaatkan *library Hugging Face Library* dan untuk proses data dengan menggunakan *tokenizer (Autotokenizer)* termasuk pembuatan *attention-mask* [17] dengan menggunakan model IndoBERT-BASE-P2 dan dilanjutkan proses *sentence embedding* dengan mengubah kalimat menjadi vector numerik sehingga dimungkinkan model dapat memahami makna semantik teks dari hasil *knowledge transfer* dalam yang telah dikonversi kedalam bentuk *encode*. Dilanjutkan proses split data sesuai dengan Standar NLP [18] menjadi 80% *data training* dan 20% *data testing* untuk memastikan bahwa data proposional sehingga validitas model dapat diukur tingkat akurasinya.

Proses untuk mengukur tingkat kemiripan antar teks dengan menggunakan Cosine Similarity dengan dilakukan perhitungan sudut cosinus antar vektor teks dan untuk mengukur akurasi model dilakukan dengan menggunakan *metrics evaluation*, yaitu dengan menghasilkan nilai *Accuracy*, *Precision*, *Recall*, dan *F1-Score* sehingga dapat ditarik sebuah kesimpulan berdasarkan hasil penelitian.



Gambar 1. Tahapan Penelitian

2.2 Data

Data yang digunakan pada penelitian ini adalah dengan menggunakan arsip [19]BAKP dan RPS yang tersedia pada Prodi Teknik Informatika. Dari keseluruhan data selama 1 semester dengan rentang waktu Semester Ganjil Tahun Akademik 2024 dengan sampel sebanyak 188 Jadwal Perkuliahan, lalu peneliti melakukan pemisahan data sesuai dengan yang dibutuhkan dan diperoleh sebanyak 38 dataset dengan menggunakan metode *Stratified Sampling* (Sampel Berstrata), data dibagi berdasarkan semester kurikulum pada mata kuliah, kemudian dilakukan perhitungan 20% dari total keseluruhan data sehingga didapatkan 20% dari 188 total jumlah jadwal perkuliahan pada semester 20241 adalah 37,6 sehingga dibulatkan menjadi 38 data [20]. Pada dataset yang diperoleh dihasilkan nama dosen, jurusan, mata kuliah, seksi, jumlah peserta, tanggal pertemuan perkuliahan, jam perkuliahan, materi kuliah, serta rekap kehadiran mahasiswa selama 1 semester seperti pada Tabel 1.

Tabel 1. Deskripsi dari Dataset

Fitur	Deskripsi
Tatap Muka Ke-Hari/Tanggal	Pertemuan Perkuliahan dengan jumlah maksimal 16 kali pertemuan. Hari dan tanggal Pelaksanaan Perkuliahan sesuai dengan jadwal yang telah ditentukan
Mulai	Catatan waktu dimulainya sesi Perkuliahan
Selesai	Catatan waktu selesai/berakhirnya pelaksanaan perkuliahan
Ruang	Tempat pelaksanaan perkuliahan
Status	Status perkuliahan
Rencana Materi	Materi yang akan disampaikan pada setiap pertemuan sesuai dengan Rencana Pembelajaran Semester (RPS)
Realisasi Materi	Materi yang disampaikan ketika pelaksanaan perkuliahan pada setiap pertemuan (BAKP)

Fitur	Deskripsi
Kehadiran Mahasiswa	Jumlah Mahasiswa yang terdata untuk kehadiran, izin, tanpa keterangan, dan sakit
Pengajar	Dosen Pengampu Mata Kuliah
Kode MK	Identitas mata kuliah dengan menggunakan aturan tertentu yang mewakili dari program studi dan nama mata kuliah
Mata Kuliah	Nama Mata Kuliah sesuai dengan kode mata kuliah
Seksi	Kelas mata kuliah

2.3 Labelling

Proses *labelling* yang dilakukan secara manual dengan mengkategorikan data berdasarkan semester mata kuliah, lalu peneliti melakukan pemisahan data sesuai dengan yang dibutuhkan dan diperoleh sebanyak 38 dataset dengan menggunakan metode Stratified Sampling (Sampel Berstrata), data dibagi berdasarkan semester kurikulum pada mata kuliah, yaitu semester 1 berjumlah 63 jadwal, semester 3 memiliki 55 jadwal, semester 5 memiliki 44 jadwal, semester 7 memiliki 22 jadwal, dan semester 8 memiliki 4 jadwal, kemudian dilakukan perhitungan 20% dari total keseluruhan data sehingga didapatkan 20% dari 188 total jumlah jadwal perkuliahan pada semester 2024/1 adalah 37,6 sehingga dibulatkan menjadi 38 data [11]. Sehingga dihasilkan data terdistribusi sebanyak 13 sampel untuk Semester 1, 11 sampel untuk Semester 3, 9 sampel untuk Semester 5, 4 sampel untuk Semester 7, dan 1 sampel untuk Semester 8.

2.4 Pre-processing Data

Praproses Data merupakan tahapan penting dalam penelitian pemrosesan bahasa alami (*Natural Language Processing* atau NLP) yang menggunakan model *Bidirectional Encoder Representations from Transformers* (BERT) dan *Semantic Textual Similarity* (STS) [21]. Pada tahap ini, data yang telah dikumpulkan dari Berita Acara Kehadiran Perkuliahan (BAKP) dan Rencana Pembelajaran Semester (RPS) akan diproses lebih lanjut untuk memastikan bahwa teks siap diolah oleh model BERT. Praproses data melibatkan beberapa langkah penting seperti *Case Folding*, *Remove punctuation*, *Stemming*, penghapusan kata tidak penting (*stopword removal*) dan *tokenizing*.

Case Folding merupakan proses standarisasi format teks untuk mengurangi variasi yang tidak penting pada data teks. Langkah ini bisa mencakup penurunan huruf kapital menjadi huruf kecil semua agar ketika proses perbandingan teks antara BAKP dengan RPS tidak terpengaruh oleh inkonsistensi huruf.

Remove punctuation adalah sebuah proses menyamakan format data agar model tidak terkecoh oleh perbedaan yang tidak memengaruhi makna semantik dengan dilakukan penghilangan tanda baca, dan penghapusan angka atau simbol yang tidak relevan. BERT sangat bergantung pada struktur teks yang konsisten, sehingga normalisasi meningkatkan akurasi dalam proses pembelajaran dan pemahaman konteks ketika proses perbandingan semantik antara BAKP dengan RPS.

Lematisasi atau *stemming* adalah proses mengubah kata-kata ke bentuk dasarnya. Lematisasi lebih canggih dibandingkan *stemming*, karena mempertimbangkan makna konteks dari kata tersebut sehingga model BERT dapat memahami berbagai varian kata yang memiliki arti yang sama [14], [22].

Stop words adalah kata-kata umum yang sering muncul dalam teks tetapi tidak memiliki kontribusi signifikan terhadap makna utama, seperti kata-kata sambung ("dan", "atau"), kata ganti ("dia", "itu"), atau kata-kata umum lainnya. Menghapus kata-kata ini membantu mengurangi noise dalam data sehingga model dapat lebih fokus pada kata-kata yang memiliki bobot semantik lebih tinggi.

Tokenizing/Tokenisasi adalah proses memecah teks menjadi unit-unit kecil yang disebut token. Dalam konteks ini, token bisa berupa kata, frasa, atau karakter individual yang merepresentasikan elemen dasar dari teks [23] dalam proses verifikasi kesesuaian materi BAKP dengan RPS secara efektif oleh model IndoBERT. Tokenisasi memiliki peranan untuk membaca dan memaknai subkata yang belum pernah ada pada saat *training* menjadi sebuah kosakata baru yang dapat dikenali oleh model serta membantu memahami makna dari kata-kata yang ada dalam teks dengan lebih tepat dan meminimalisir ambiguitas dalam interpretasi teks. Misal, pada kata "menjelas" dan "penjelasan" dapat dipahami bahwa kata tersebut dari kata dasar "jelas" dan tokenisasi membantu dalam memahami variasi kata yang memiliki imbuhan baik diawal atau pun akhir kata serta peranan lainnya, yaitu untuk dapat mengenali makna antar kata dalam istilah asing, seperti *deep learning* yang dapat dipecah menjadi "*deep*" dan "*learning*".

2.5 IndoBERT

Pada tahap ketiga, setelah data dikumpulkan dan dilakukan praproses, model BERT (*Bidirectional Encoder Representations from Transformers*) diterapkan melalui dua langkah utama, yaitu *pratraining* dan *fine-tuning*. Tahapan ini adalah bagian inti dari proses verifikasi kesesuaian materi pembelajaran karena BERT digunakan untuk memproses teks dalam pembelajaran dan hasil evaluasi untuk menghasilkan representasi vektor dari teks yang kemudian dapat dibandingkan menggunakan teknik *Semantic Textual Similarity* (STS) [24].

Model IndoBERT merupakan salah satu hasil pre-trained dari model BERT yang dirancang khusus untuk Bahasa Indonesia berbasis transformer [25]. Tujuan model ini dibuat untuk meningkatkan proses *Natural Language Processing* (NLP) yang menggunakan Bahasa Indonesia agar dapat merepresentasikan kontekstual pemahaman yang lebih mendalam dalam sebuah kalimat atau teks [26] IndoBERT dilakukan pelatihan menggunakan corpus yang besar

dengan melakukan penggabungan lebih dari 220 juta kata dari kosakata substansial, termasuk media sosial, berita serta artikel yang berbahasa indonesia dengan menggunakan *Masked Language Model* (MLM) dan *Next Sentence Prediction* (NSP) [27].

Setelah model BERT dilatih secara umum, langkah berikutnya adalah *fine-tuning*. *Fine-tuning* adalah proses menyesuaikan model BERT dengan data spesifik dari domain yang akan dianalisis, dalam hal ini, BAKP dan RPS di Prodi Teknik Informatika ITPLN. Proses ini melibatkan pelatihan tambahan pada dataset yang lebih kecil dan spesifik, agar model lebih sensitif terhadap konteks yang ada dalam materi ajar. Sebelum *fine-tuning*, teks dari BAKP dan RPS harus di-tokenize. Tokenisasi adalah proses memecah teks menjadi bagian-bagian kecil yang disebut "token" agar model dapat memprosesnya. BERT menggunakan *WordPiece tokenization* yang memecah kata menjadi sub-kata atau token untuk menangani variasi linguistik yang kompleks. Pada proses ini dilakukan pemanggilan model dengan menggunakan transformers yang sudah ada, yaitu *Hugging Face Library* dan untuk proses data dengan menggunakan *tokenizer* (*Autotokenizer*) termasuk pembuatan *attention-mask* [17] dengan menggunakan model IndoBERT-BASE-P2.

BERT hanya memerlukan *encoder* untuk menghasilkan sebuah model bahasa [28]. Secara *original* transformer hanya memiliki 6 layer dengan jumlah representasi *vector* sebanyak $d_{model} = 512$ dimensi. Untuk variasi *base* representasi sebanyak 768 dimensi dan 12 encoder layers sedangkan untuk *large* sebanyak 24 *encoder layers* dengan 1024 dimensi.

2.6 Cosine Similarity

Pada dokumen masing-masing, yaitu BAKP (A) dengan RPS (B), setelah selesai dilakukan proses *embedding*, kemudian dilakukan perhitungan *score similarity* untuk mengukur tingkat kesamaan teks antar kedua dokumen [29] dengan menentukan skor *threshold* kesamaan, dimana hasil akan ditunjukkan dengan rentang angka dari 0 sampai dengan 1, 0 merupakan paling tidak sesuai atau tidak sama, sedangkan 1 menunjukkan bahwa teks antar kedua dokumen memiliki tingkat kesamaan identik [30]. Persamaan Cosine Similarity adalah sebagai berikut :

$$\text{Cosine Similarity} = \frac{A \cdot B}{\|A\| \cdot \|B\|} \quad (1)$$

2.7 Evaluation Metrics

Perhitungan *Accuracy*, *Precision*, *Recall*, dan *F1-Score* dilakukan guna untuk melakukan evaluasi dari prediksi kesesuaian teks dengan mengkategorikan "match" atau "mismatch" dengan rumus sebagai berikut:

$$\text{Accuracy} = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (2)$$

Precision untuk mengukur proporsi prediksi positif yang benar-benar positif

$$\text{Precision} = \frac{TP}{TP.FP} \quad (3)$$

Recall yang dikenal juga sebagai sensitivitas yang berguna untuk mengukur proporsi data positif yang berhasil diidentifikasi atau yang dianggap relevan oleh model,

$$\text{Recall} = \frac{TP}{TP.FN} \quad (4)$$

F1-Score adalah matriks yang menggabungkan *Precision* dengan *Recall* menjadi sebuah nilai untuk menyeimbangkan antara kesalahan *False Positive* dengan *False Negative* dengan range nilai 0 sebagai nilai terburuk dan 1 sebagai nilai terbaik.

$$F1 - \text{Score} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

3. HASIL DAN PEMBAHASAN

Penelitian ini dilakukan implementasi model IndoBERT dan Cosine Similarity pada objek penelitian yaitu dokumen Berita Acara Kehadiran Perkuliahan (BAKP) dan Rencana Pembelajaran Semester (RPS) Program Studi S1 Teknik Informatika Institut Teknologi PLN, maka didapatkan hasilnya sebagai berikut ini.

3.1 Pengumpulan Dataset dan Labelling

Proses dimulai dengan mengumpulkan data BAKP dan RPS dari Program Studi Teknik Informatika. Total data yang dikumpulkan adalah 188 Jadwal Perkuliahan pada Semester Ganjil Tahun Akademik 2024. Selanjutnya adalah melakukan proses *labelling* yang dilakukan secara manual dengan mengkategorikan data berdasarkan semester mata kuliah, lalu peneliti melakukan pemisahan data sesuai dengan yang dibutuhkan dan diperoleh sebanyak 38 dataset dengan menggunakan metode *Stratified Sampling* (Sampel Berstrata), data dibagi berdasarkan semester kurikulum pada mata kuliah, yaitu semester 1 berjumlah 63 jadwal, semester 3 memiliki 55 jadwal, semester 5 memiliki 44 jadwal, semester 7 memiliki 22 jadwal, dan semester 8 memiliki 4 jadwal, kemudian dilakukan perhitungan 20% dari

total keseluruhan data sehingga didapatkan 20% dari 188 total jumlah jadwal perkuliahan pada semester 20241 adalah 37,6 sehingga dibulatkan menjadi 38 data [11]. Sehingga dihasilkan data terdistribusi sebanyak 13 sampel untuk Semester 1, 11 sampel untuk Semester 3, 9 sampel untuk Semester 5, 4 sampel untuk Semester 7, dan 1 sampel untuk Semester 8 seperti ditunjukkan dengan Tabel 2 dibawah ini.

Tabel 1. Hasil *Labelling*

Label	Jumlah Proporsi per Strata	Jumlah <i>Stratified Sampling</i>
Semester 1	63	13
Semester 3	55	11
Semester 5	44	9
Semester 7	22	4
Semester 8	4	1

3.2 Pre-processing Data

Pada tahap ini dilakukan implementasi beberapa proses, seperti *case folding* dengan fungsi untuk mengubah semua huruf menjadi standar huruf kecil, kemudian *remove punctuation* bertugas untuk menghilangkan tanda baca dan simbol, *stemming* untuk mengubah kata ke bentuk dasarnya, *stopword removal* berfungsi untuk menghapus kata-kata umum yang tidak signifikan, dan *tokenizing* untuk memecah teks menjadi unit-unit kecil sehingga dihasilkan data seperti pada Tabel 3.

Tabel 2. *Pre-processing Data*

Proses	Kalimat
<i>Initial</i>	BAKP <i>Texts</i> : ['Penjelasan RPS satu semester, Kotrak Perkuliahan, Tugas, dan evaluasi'] RPS <i>Texts</i> : [' Mampu menjelaskan konsep manusia dan alam semesta menurut Islam ditinjau dari Al Quran dan Hadist, serta mampu menyatakan hubungan manusia dan alam dengan baik.']
<i>Case Folding</i>	BAKP <i>Texts</i> : penjelasan rps satu semester, kotrak perkuliahan, tugas, dan evaluasi RPS <i>Texts</i> : mampu menjelaskan konsep manusia dan alam semesta menurut islam ditinjau dari al quran dan hadist, serta mampu menyatakan hubungan manusia dan alam dengan baik.
<i>Remove Punctuation</i>	BAKP <i>Texts</i> : penjelasan rps satu semester kotrak perkuliahan tugas dan evaluasi RPS <i>Texts</i> : mampu menjelaskan konsep manusia dan alam semesta menurut islam ditinjau dari al quran dan hadist serta mampu menyatakan hubungan manusia dan alam dengan baik
<i>Stemming</i>	BAKP <i>Texts</i> : penjelasan rps satu semester kotrak perkuliahan tugas dan evaluasi RPS <i>Texts</i> : mampu menjelaskan konsep manusia dan alam semesta menurut islam ditinjau dari al quran dan hadist, serta mampu menyatakan hubungan manusia dan alam dengan baik.
<i>Stopword Removal</i>	BAKP <i>Texts</i> : penjelasan rps semester kotrak perkuliahan tugas evaluasi RPS <i>Texts</i> : mamp menjelas konsep manusia alam semesta islam tinjau al quran hadist mampu nyata hubungan manusia alam dengan
<i>Tokenizing</i>	BAKP <i>Texts</i> : ['penjelasan', 'rps', 'semester', 'kotrak', 'perkuliahan', 'tugas', 'evaluasi'] RPS <i>Texts</i> : ['mampu', 'menjelas', 'konsep', 'manusia', 'alam', 'semesta', 'islam', 'tinjau', 'al', 'quran', 'hadist', 'mampu', 'nyata', 'hubungan', 'manusia', 'alam', 'dengan']

3.3 IndoBERT

Pada proses ini model berbasis BERT, yaitu IndoBERT digunakan sebagai model khusus Bahasa Indonesia dengan menggunakan pustaka dari *Hugging Face Transformers* untuk dilakukan *tokenizer* dan menggunakan model *indobenchmark/indobert-base-p2*.

Pada IndoBERT hanya dilakukan proses *encoder* saja untuk menghasilkan representasi numerik (*embedding*) untuk setiap teks input dengan menggunakan token [CLS] yang mengubah token menjadi tensor PyTorch. Hasil pada Tabel 4 merupakan vektor *embedding* yang digunakan untuk proses perhitungan Cosine Similarity.

Tabel 3. Hasil *Encoding* BAKP dan RPS Teks 5 Baris Pertama

Hasil Encoding BAKP (5 baris pertama)	Hasil Encoding RPS (5 baris pertama):
Dokumen BAKP 1: tensor([-1.0737, 3.5555, -0.1047, 0.2840, 1.6401], grad_fn=<SliceBackward0>)	Dokumen RPS 1: tensor([-1.1755, 2.7672, -0.4993, 0.7685, 1.5430], grad_fn=<SliceBackward0>)
Dokumen BAKP 2: tensor([-1.3114, 2.8632, -0.4256, 0.9872, 1.2881], grad_fn=<SliceBackward0>)	Dokumen RPS 2: tensor([-1.1755, 2.7672, -0.4993, 0.7685, 1.5430], grad_fn=<SliceBackward0>)
Dokumen BAKP 3: tensor([-2.3227, 1.4775, 0.2146, -0.2261, 1.9779], grad_fn=<SliceBackward0>)	Dokumen RPS 3: tensor([-1.6226, 4.2200, -0.2685, 1.0420, 0.6780], grad_fn=<SliceBackward0>)



Hasil Encoding BAKP (5 baris pertama)	Hasil Encoding RPS (5 baris pertama):
Dokumen BAKP 4: tensor([-2.5861, 3.1668, -1.3511, 0.5138, 1.1618], grad_fn=<SliceBackward0>)	Dokumen RPS 4: tensor([-1.6226, 4.2200, -0.2685, 1.0420, 0.6780], grad_fn=<SliceBackward0>)
Dokumen BAKP 5: tensor([-0.8477, 2.4256, -0.3779, 0.6748, 1.6120], grad_fn=<SliceBackward0>)	Dokumen RPS 5: tensor([-1.3865, 2.7411, -0.2866, -0.1487, 1.4484], grad_fn=<SliceBackward0>)

3.4 Cosine Similarity

Knowledge transfer dari hasil representasi vektor *embedding* model IndoBERT dari teks BAKP (*bakp_embeddings*) dan RPS (*rps_embeddings*) digunakan pada proses perhitungan kesamaan dengan menggunakan Cosine Similarity, pada proses ini dilakukan perhitungan nilai kesamaan kosinus antar seluruh pasangan dari *bakp_embeddings* dan *rps_embeddings* sehingga dihasilkan sebuah matriks kesamaan dengan ukuran sesuai dengan jumlah teks BAKP dan RPS yang ditunjukkan pada tabel dibawah ini ditunjukkan dengan Tabel 5.

Tabel 4. Perhitungan Cosine Similarity Per Dokumen BAKP dan RPS

	RPS_1	RPS_2	RPS_3	RPS_4	RPS_5
BAKP_1	0,74	0,74	0,74	0,74	0,73
BAKP_2	0,80	0,80	0,65	0,65	0,73
BAKP_3	0,79	0,79	0,61	0,61	0,60
BAKP_4	0,80	0,80	0,70	0,70	0,70
BAKP_5	0,71	0,71	0,65	0,65	0,65
BAKP_6	0,76	0,76	0,59	0,59	0,75
BAKP_7	0,79	0,79	0,63	0,63	0,76
BAKP_8	0,40	0,40	0,33	0,33	0,45
BAKP_9	0,73	0,73	0,59	0,59	0,70
BAKP_10	0,82	0,82	0,70	0,70	0,80
BAKP_11	0,67	0,67	0,58	0,58	0,72
BAKP_12	0,70	0,70	0,62	0,62	0,67
BAKP_13	0,71	0,71	0,55	0,55	0,69
BAKP_14	0,68	0,68	0,58	0,58	0,68
BAKP_15	0,72	0,72	0,64	0,64	0,68
BAKP_16	0,53	0,53	0,43	0,43	0,58


	RPS_6	RPS_7	RPS_8	RPS_9	RPS_10
BAKP_1	0,73	0,69	0,69	0,68	0,68
BAKP_2	0,73	0,61	0,58	0,73	0,73
BAKP_3	0,60	0,54	0,47	0,66	0,66
BAKP_4	0,70	0,64	0,59	0,68	0,68
BAKP_5	0,65	0,60	0,48	0,70	0,70
BAKP_6	0,75	0,54	0,58	0,69	0,69
BAKP_7	0,76	0,60	0,57	0,67	0,67
BAKP_8	0,45	0,38	0,61	0,33	0,33
BAKP_9	0,70	0,51	0,71	0,60	0,60
BAKP_10	0,80	0,63	0,61	0,73	0,73
BAKP_11	0,72	0,58	0,54	0,64	0,64
BAKP_12	0,67	0,55	0,53	0,69	0,69
BAKP_13	0,69	0,50	0,69	0,53	0,53
BAKP_14	0,68	0,51	0,64	0,60	0,60
BAKP_15	0,68	0,61	0,42	0,75	0,75
BAKP_16	0,58	0,49	0,58	0,41	0,41

	RPS_11	RPS_12	RPS_13	RPS_14	RPS_15	RPS_16
BAKP_1	0,68	0,75	0,75	0,75	0,75	0,61
BAKP_2	0,73	0,71	0,71	0,72	0,72	0,46
BAKP_3	0,66	0,57	0,57	0,60	0,60	0,50
BAKP_4	0,68	0,72	0,72	0,73	0,73	0,48
BAKP_5	0,70	0,68	0,68	0,68	0,68	0,47
BAKP_6	0,69	0,63	0,63	0,64	0,64	0,56
BAKP_7	0,67	0,68	0,68	0,67	0,67	0,51
BAKP_8	0,33	0,39	0,39	0,34	0,34	0,71
BAKP_9	0,60	0,84	0,84	0,68	0,68	0,43

	RPS_11	RPS_12	RPS_13	RPS_14	RPS_15	RPS_16
BAKP_10	0,73	0,74	0,74	0,74	0,74	0,50
BAKP_11	0,64	0,59	0,59	0,60	0,60	0,60
BAKP_12	0,69	0,70	0,70	0,71	0,71	0,35
BAKP_13	0,53	0,65	0,65	0,62	0,62	0,45
BAKP_14	0,60	0,70	0,70	0,67	0,67	0,43
BAKP_15	0,75	0,64	0,64	0,69	0,69	0,49
BAKP_16	0,41	0,42	0,42	0,39	0,39	0,97

3.5 Splitting Data

Hasil perhitungan dari kesamaan dengan menggunakan Cosine, selanjutnya data terbagi menjadi 80% sebagai data latihan dan 20% seperti ditunjukkan pada Gambar 2 sebagai data pengujian untuk memungkinkan evaluasi *metrics* terhadap performa model dengan hasil seperti pada tabel berikut dengan dilakukan kategorisasi berdasarkan nilai ambang batas atau *threshold* sebesar 0.50. Pembagian data ini merupakan sebuah standar *Deep Learning* untuk *Natural Language Processing* [18] guna untuk memperoleh keseimbangan antara *training* dan *testing* serta proporsi ini dapat menghindari *overfitting* dikarenakan data latih terlalu besar sehingga buruk dalam mengenali data baru ataupun data uji terlalu besar sehingga mengakibatkan model tidak belajar dengan baik dari minim nya data latih.



Gambar 2. Splitting Data

Hasil dari data latih dihasilkan sebagai berikut pada Tabel 6 dan hasil data uji dihasilkan seperti pada Tabel 7. Setiap pasangan teks BAKP dan RPS akan dilakukan pengkategorian *match* dan *mismatch*, *match* jika nilai *similarity* \geq *threshold* dan dikategorikan *mismatch* jika nilai *similarity* $<$ *threshold*.

Tabel 6. Data Latih (16 baris pertama)

	BAKP	RPS	Similarity	Category
143	BAKP_9	RPS_16	0.434250	mismatch
84	BAKP_6	RPS_5	0.749059	match
55	BAKP_4	RPS_8	0.585032	match
220	BAKP_14	RPS_13	0.700025	match
104	BAKP_7	RPS_9	0.672274	match
139	BAKP_9	RPS_12	0.839574	match
127	BAKP_8	RPS_16	0.708984	match
60	BAKP_4	RPS_13	0.719592	match
101	BAKP_7	RPS_6	0.759027	match
172	BAKP_11	RPS_13	0.593065	match
245	BAKP_16	RPS_6	0.578066	match
126	BAKP_8	RPS_15	0.341343	mismatch
225	BAKP_15	RPS_2	0.721608	match
144	BAKP_10	RPS_1	0.818454	match
108	BAKP_7	RPS_13	0.681033	match
178	BAKP_12	RPS_3	0.621207	match

Tabel 5. Data Uji (16 baris pertama)

	BAKP	RPS	Similarity	Category
228	BAKP_15	RPS_5	0.681172	match
6	BAKP_1	RPS_7	0.688663	match
79	BAKP_5	RPS_16	0.466534	mismatch
206	BAKP_13	RPS_15	0.624800	match
117	BAKP_8	RPS_6	0.454921	mismatch
185	BAKP_12	RPS_10	0.685738	match
242	BAKP_16	RPS_3	0.428529	mismatch
167	BAKP_11	RPS_8	0.537319	match
9	BAKP_1	RPS_10	0.675753	match
30	BAKP_2	RPS_15	0.720338	match



180	BAKP_12	RPS_5	0.670510	match
222	BAKP_14	RPS_15	0.673442	match
230	BAKP_15	RPS_7	0.609766	match
217	BAKP_14	RPS_10	0.598128	match
136	BAKP_9	RPS_9	0.599079	match
68	BAKP_5	RPS_5	0.649030	match

3.6 Evaluation IndoBERT

Data Pengujian diolah untuk melakukan efisiensi komputasi dengan mengubah skor *similarity* menjadi prediksi kategorikal dengan hasil prediksi *match* sebagai 1 dan *mismatch* sebagai 0. Hasil ini seperti pada Tabel 8. digunakan sebagai dasar untuk analisis performa *evaluation metrics*, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*.

Tabel 6. Evaluating IndoBERT

All Predictions and True Labels:
Sample 1: Predicted: 1, True Label: 1
Sample 2: Predicted: 1, True Label: 1
Sample 3: Predicted: 0, True Label: 0
Sample 4: Predicted: 1, True Label: 1
Sample 5: Predicted: 0, True Label: 0
Sample 6: Predicted: 1, True Label: 1
Sample 7: Predicted: 0, True Label: 0
Sample 8: Predicted: 1, True Label: 1
Sample 9: Predicted: 1, True Label: 1
Sample 10: Predicted: 1, True Label: 1
Sample 11: Predicted: 1, True Label: 1
Sample 12: Predicted: 1, True Label: 1
Sample 13: Predicted: 1, True Label: 1
Sample 14: Predicted: 1, True Label: 1
Sample 15: Predicted: 1, True Label: 1
Sample 16: Predicted: 1, True Label: 1
Sample 17: Predicted: 1, True Label: 1
Sample 18: Predicted: 1, True Label: 1
Sample 19: Predicted: 1, True Label: 1
Sample 20: Predicted: 1, True Label: 1
Sample 21: Predicted: 1, True Label: 1
Sample 22: Predicted: 1, True Label: 1
Sample 23: Predicted: 0, True Label: 0
Sample 24: Predicted: 1, True Label: 1
Sample 25: Predicted: 1, True Label: 1
Sample 26: Predicted: 0, True Label: 0
Sample 27: Predicted: 0, True Label: 0
Sample 28: Predicted: 1, True Label: 1
Sample 29: Predicted: 1, True Label: 1
Sample 30: Predicted: 1, True Label: 1
Sample 31: Predicted: 1, True Label: 1
Sample 32: Predicted: 1, True Label: 1
Sample 33: Predicted: 1, True Label: 1
Sample 34: Predicted: 1, True Label: 1
Sample 35: Predicted: 0, True Label: 0
Sample 36: Predicted: 1, True Label: 1
Sample 37: Predicted: 1, True Label: 1
Sample 38: Predicted: 1, True Label: 1
Sample 39: Predicted: 1, True Label: 1
Sample 40: Predicted: 1, True Label: 1
Sample 41: Predicted: 1, True Label: 1
Sample 42: Predicted: 1, True Label: 1
Sample 43: Predicted: 0, True Label: 0
Sample 44: Predicted: 1, True Label: 1
Sample 45: Predicted: 1, True Label: 1
Sample 46: Predicted: 1, True Label: 1
Sample 47: Predicted: 1, True Label: 1

All Predictions and True Labels:	
Sample 48:	Predicted: 1, True Label: 1
Sample 49:	Predicted: 1, True Label: 1
Sample 50:	Predicted: 1, True Label: 1
Sample 51:	Predicted: 1, True Label: 1

Selanjutnya dilakukan evaluasi performa dengan melakukan perhitungan *evaluation metrics*, yaitu untuk menghasilkan nilai *accuracy*, *precision*, *recall*, dan *F-1 Score* dengan data sejumlah 38 sampel data dan dihasilkan untuk masing-masing nilai *accuracy*, *precision*, *recall*, dan *F-1 Score* dengan data sebagai berikut pada **Tabel 9**.

Tabel 7. Hasil *Evaluation Metrics*

Kode MK	Seksi	Cosine Similarity	Accuracy	Precision	Recall	F1-Score
MKI010101	D31	0,694	1,00	1,00	1,00	1,00
MKI010101	E31	0,762	1,00	1,00	1,00	1,00
MKI010101	Q	0,989	1,00	1,00	1,00	1,00
C31010103	B	0,638	1,00	1,00	1,00	1,00
C31010103	C	0,622	1,00	1,00	1,00	1,00
C31010103	D	0,649	1,00	1,00	1,00	1,00
C31010101	E	0,657	1,00	1,00	1,00	1,00
C31010105	F	0,689	1,00	1,00	1,00	1,00
C31010102	C	0,613	1,00	1,00	1,00	1,00
MKI010601	A31	0,715	1,00	1,00	1,00	1,00
MKI010601	F31	0,715	1,00	1,00	1,00	1,00
C31010104	A	0,708	1,00	1,00	1,00	1,00
C31010104	D	0,630	1,00	1,00	1,00	1,00
C31010303	E	0,602	1,00	1,00	1,00	1,00
C31010303	G	0,667	1,00	1,00	1,00	1,00
C31010305	A	0,674	1,00	1,00	1,00	1,00
C31010305	F	0,659	1,00	1,00	1,00	1,00
C31010305	G	0,649	1,00	1,00	1,00	1,00
C31010304	B	0,679	1,00	1,00	1,00	1,00
C31010308	A	0,695	1,00	1,00	1,00	1,00
C31010302	E	0,745	1,00	1,00	1,00	1,00
C31010307	B	0,870	1,00	1,00	1,00	1,00
C31010307	C	0,613	1,00	1,00	1,00	1,00
C31010306	D	0,619	1,00	1,00	1,00	1,00
TEN010502	D31	0,650	1,00	1,00	1,00	1,00
C31010502	F	0,693	1,00	1,00	1,00	1,00
C31010504	B	0,753	1,00	1,00	1,00	1,00
C31010504	D	0,692	1,00	1,00	1,00	1,00
C31010501	A	0,678	1,00	1,00	1,00	1,00
C31010501	C	0,652	1,00	1,00	1,00	1,00
TEN010501	A31	0,666	1,00	1,00	1,00	1,00
TEN010501	B31	0,630	1,00	1,00	1,00	1,00
TEN010501	E31	0,663	1,00	1,00	1,00	1,00
C31010702	A	0,479	1,00	1,00	1,00	1,00
C31010702	C	0,506	1,00	1,00	1,00	1,00
C31010704	C	0,638	1,00	1,00	1,00	1,00
C31012703	B	0,714	1,00	1,00	1,00	1,00
C31011806	A	0,665	1,00	1,00	1,00	1,00

3.7 Summary

Berdasarkan hasil perhitungan dengan menggunakan model IndoBERT dan Cosine Similarity serta *evaluation metrics*, maka didapatkan rerata untuk nilai dari masing hasil evaluasi untuk verifikasi kesesuaian materi pembelajaran pada Program Studi Teknik Informatika pada Semester Ganjil Tahun Akademik 2024/2025 dengan hasil seperti pada Tabel 10 berikut:

Tabel 8. Hasil Rata-rata dari *Evaluation Model*

Cosine Similarity	Accuracy	Precision	Recall	F1-Score
0,674	1,00	1,00	1,00	1,00

Nilai Cosine Similarity sebesar 0,674 dengan *threshold* 0,50 menunjukkan bahwa materi yang disampaikan oleh dosen pengampu di kelas sudah sesuai dengan capaian materi yang terdapat pada RPS dan hasil *evaluation metrics* menunjukkan bahwa data sempurna. Nilai Akurasi menunjukkan model dapat memprediksi 100% pasangan teks dengan benar, *precision* dengan nilai 1,000 menunjukkan bahwa dari semua pasangan yang diprediksi sebagai *match* 100% benar-benar *match*, *recall* 100% menunjukkan bahwa semua pasangan yang benar-benar *match* terdeteksi oleh model dan model memiliki keseimbangan yang baik antara *precision* dengan *recall* ditunjukkan dengan didapatkan *F1-Score* 100%.

4. KESIMPULAN

Berdasarkan dari hasil penerapan model *Bidirectional Encoder Representations from Transformers* (BERT) khusus bahasa Indonesia, yaitu IndoBERT dan Cosine Similarity dengan menggunakan dataset Berita Acara Kehadiran Perkuliahan (BAKP) dan Rencana Pembelajaran Semester (RPS) pada Program Studi S1 Teknik Informatika Institut Teknologi PLN untuk proses verifikasi kesesuaian materi pembelajaran. Berdasarkan hasil pengujian dengan model IndoBERT dan perhitungan kesamaan Cosine Similarity dihasilkan nilai akurasi rata-rata 67,4% dan nilai *evaluation metrics* sebesar 100% yang merupakan hasil dari nilai *accuracy* 100% (1,000), nilai *precision* sebesar 100% (1,000), nilai *recall* 100% (1,000) dan nilai *F1-Score* 100% (1,000) dari hasil keseimbangan antara *precision* dengan *recall*. Hal ini menunjukkan bahwa Model IndoBERT dapat menunjukkan performa dengan sangat baik dalam melakukan verifikasi kesesuaian materi pembelajaran antara Berita Acara Kehadiran Perkuliahan dengan Rencana Pembelajaran Semester pada penelitian ini. Selanjutnya penelitian dapat menggunakan dataset lebih besar dan diimplementasikan untuk pengembangan sistem rekomendasi materi pembelajaran dan juga sebagai sistem otomatis evaluasi kualitas kesesuaian materi pembelajaran.

REFERENCES

- [1] UNESCO, *Global Education Monitoring Report 2024: Pacific: Technology in education – A tool on whose terms*. GEM Report UNESCO; Commonwealth of Learning, 2024. doi: 10.54676/FILL2531.
- [2] Permendikbud, “Permendikbud-Nomor-3-Tahun-2020,” 2020.
- [3] World Economic Forum, “Our Institutional Framework Leadership and Governance Policies, Terms and Codes.” Accessed: Feb. 27, 2025. [Online]. Available: <https://www.weforum.org/stories/2024/08/global-youth-employment-future-jobs/>
- [4] Kemendikbud, “Keputusan Menteri Pendidikan Dan Kebudayaan Republik Indonesia-Nomor-3_M_2021,” 2021, Accessed: Mar. 27, 2024. [Online]. Available: jdih.kemdikbud.go.id
- [5] M. Pratiwi, D. Yuliana Fitri, and A. Cesaria, “The Development of Inquiry-Based Teaching Materials for Basic Algebra Courses: Integration with Guided Note-Taking Learning Models,” *MATHEMATICS TEACHING RESEARCH JOURNAL*, vol. 192, no. 4, 2022.
- [6] M. H. Husni, A. Agung Ngurah Sedana Putra, and D. Purnama Dewata, “Development of Digitalization of Semester Learning Plans for Room Reservation Courses in the Room Division Study Program Lombok Tourism Polytechnic,” *International Journal of Humanities Education and Social Sciences*, Vol 3, No 5, 2024, doi.org/10.55227/ijhess.v3i5.844
- [7] Kementistekdikti RI, “Standar Nasional Pendidikan Tinggi PERMENRISTEKDIKTI Nomor 44 Tahun 2015 SNPT,” Dec. 2015.
- [8] V. Efimov, “Large Language Models: BERT — Bidirectional Encoder Representations from Transformer.” Accessed: Aug. 24, 2024. [Online]. Available: <https://towardsdatascience.com/bert-3d1bf880386a>
- [9] D. Y. Dengyun Zhu, Hailong Gai, Fucheng Wan, “Semantic Similarity Calculating based on BERT,” *Journal of Electrical Systems*, vol. 20, no. 2, pp. 73–79, Apr. 2024, doi: 10.52783/jes.1099.
- [10] D. Viji and S. Revathy, “A hybrid approach of Weighted Fine-Tuned BERT extraction with deep Siamese Bi – LSTM model for semantic text similarity identification,” *Multimed Tools Appl*, vol. 81, no. 5, pp. 6131–6157, Feb. 2022, doi: 10.1007/s11042-021-11771-6.
- [11] B. Whalley, D. France, J. Park, A. Mauchline, and K. Welsh, “Towards flexible personalized learning and the future educational system in the fourth industrial revolution in the wake of Covid-19,” *High Educ Pedagog*, vol. 6, no. 1, pp. 79–99, 2021, doi: 10.1080/23752696.2021.1883458.
- [12] N. L. Rane, “Education 4.0 and 5.0: integrating Artificial Intelligence (AI) for personalized and adaptive learning,” *Journal of Artificial Intelligence and Robotics*, Jun. 2024, doi: 10.61577/jaiar.2024.100006.
- [13] L. I. González-pérez and M. S. Ramírez-montoya, “Components of Education 4.0 in 21st Century Skills Frameworks: Systematic Review,” *MDPI*, Feb. 01, 2022., doi: 10.3390/su14031493.
- [14] Sudarshan Joshi, Akshay Bachkar, Omkar Awaje, Rhutuj Bhoir, and Kimaya Urane, “Automated Answersheet Evaluation using BERT,” *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, vol. 10, no. 3, pp. 624–631, Jun. 2024, doi: 10.32628/cseit2410337.
- [15] N. Reimers and I. Gurevych, “Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks,” pp. 3982–3992, 2019, doi: 10.18653/v1/D19-1410.
- [16] V. Goel, D. Sahnun, V. V. G. Sharma, D. Dwivedi, and M. Mohania, “K-12BERT: BERT for K-12 education,” May 2022, [Online]. Available: <http://arxiv.org/abs/2205.12335>



- [17] Anugerah Simanjuntak *et al.*, “Research and Analysis of IndoBERT Hyperparameter Tuning in Fake News Detection,” *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 13, no. 1, pp. 60–67, Feb. 2024, doi: 10.22146/jnteti.v13i1.8532.
- [18] S. Raaijmakers, *Deep Learning for Natural Language Processing*. Shelter Island: Manning Publications Co, 2022.
- [19] D. Sutrisno, A. Yuliana Dewi, I. Rosyadi, and M. Informatika, “Rancang Bangun Aplikasi Instrumen Perkuliahan Pada Fakultas Teknik dan Ilmu Komputer UMPP Berbasis WEB,” *SURYA INFORMATIKA*, vol. 13, no. 1, May 2023.
- [20] D. Firmansyah and Dede, “Teknik Pengambilan Sampel Umum dalam Metodologi Penelitian: Literature Review,” *Jurnal Ilmiah Pendidikan Holistik (JIPH)*, vol. 1, no. 2, pp. 85–114, Aug. 2022, doi: 10.55927/jiph.v1i2.937.
- [21] A. Scarlatos, C. Brinton, and A. Lan, “Process-BERT: A Framework for Representation Learning on Educational Process Data,” Apr. 2022, [Online]. Available: <http://arxiv.org/abs/2204.13607>
- [22] K. Datchanamoorthy, A. Mala. G. S, and Padmavathi. B, “Text Mining: Clustering Using Bert And Probabilistic Topic Modeling,” *Social Informatics Journal*, vol. 2, no. 2, pp. 1–13, Dec. 2023, doi: 10.58898/sij.v2i2.01-13.
- [23] Denis. Rothman, *Transformers for Natural Language Processing Rothman, Denis*. Packt Publishing, 2021.
- [24] sbert.net, “Semantic Textual Similarity.” Accessed: Aug. 24, 2024. [Online]. Available: <https://sbert.net/examples/training/sts/README.html>
- [25] E. Dave and A. Chowanda, “Indonesian personal financial entity extraction using indoBERT-BiGRU-CRF model,” *J Big Data*, vol. 11, no. 1, Dec. 2024, doi: 10.1186/s40537-024-00987-6.
- [26] F. Koto, A. Rahimi, J. H. Lau, and T. Baldwin, “IndoLEM and IndoBERT: A Benchmark Dataset and Pre-trained Language Model for Indonesian NLP,” pp. 757–770, Nov. 2020, doi: 10.48550/arXiv.2011.00677.
- [27] D. Suhartono, M. R. N. Majiid, and R. Fredyan, “Towards automatic question generation using pre-trained model in academic field for Bahasa Indonesia,” *Educ Inf Technol (Dordr)*, Nov. 2024, doi: 10.1007/s10639-024-12717-9.
- [28] S. Sofiana, *Konsep-BERT pada Natural Language Processing*. Eureka Media Aksara, 2024.
- [29] D. Khurana, A. Koli, K. Khatter, and S. Singh, “Natural language processing: state of the art, current trends and challenges,” *Multimed Tools Appl*, vol. 82, no. 3, pp. 3713–3744, Jan. 2023, doi: 10.1007/s11042-022-13428-4.
- [30] Y. T. Jin, J. B. You, S. Wakamiya, and H. Y. Kwon, “Analyzing user reactions using relevance between location information of tweets and news articles,” *EPJ Data Sci*, vol. 13, no. 1, Dec. 2024, doi: 10.1140/epjds/s13688-024-00465-2.