

Bidirectional Long Short-Term Memory Model for Intent Classification in Customer Service Chatbot

Yagus Cahyadi^{1*}, Sri Redjeki², Ahmad Almagribi³, Bayu Satriani⁴, Nabil Naufal⁵

^{1,2,3} Magister Teknologi Informasi, Fakultas Teknologi Informasi, Universitas Teknologi Digital Indonesia, Yogyakarta, 55198, Indonesia

^{4,5} Informatika, Fakultas Teknologi Informasi, Universitas Teknologi Digital Indonesia, Yogyakarta, 55198, Indonesia

Informasi Artikel

Diterima : 21 Februari 2025
Revisi : 14 Maret 2025
Publikasi : 20 Maret 2025

Kata Kunci:

Chatbot
RNN
LSTM
Bi LSTM
Intent

ABSTRAK

Kebutuhan akan layanan pelanggan yang responsif dan efisien menjadi salah satu aspek krusial dalam meningkatkan kepuasan pelanggan, terutama di lingkungan kantor pemerintahan Indonesia di luar negeri. Salah satu pendekatan untuk mengatasi tantangan ini adalah dengan menggunakan mesin chatbot berbasis Bidirectional Long Short-Term Memory. Algoritma ini mampu memahami konteks percakapan secara lebih mendalam, sehingga dapat memberikan respons yang relevan dan tepat waktu. Penelitian ini dilakukan untuk mengoptimalkan performa chatbot dalam meningkatkan pengalaman pelanggan melalui implementasi algoritma Bi LSTM untuk menangani klasifikasi intent data masukan dari pelanggan. Hasil eksperimen menunjukkan bahwa model ini mampu meningkatkan skor evaluasi, termasuk akurasi 84,64%, precision 85%, recall 85% dan F1-score 85%.

ABSTRACT

The demand for responsive and efficient customer service is a crucial aspect of enhancing customer satisfaction, particularly in Indonesian government offices abroad. To address this challenge is implementing a chatbot system based on Bidirectional Long Short-Term Memory. This model can understand conversational contexts more comprehensively, enabling it to generate relevant and timely responses. This study aims to optimize chatbot performance in enhancing customer experience by implementing the Bi LSTM algorithm to handle intent classification of customer input data. Experimental results demonstrate that this model successfully improves evaluation metrics, achieving an accuracy of 84.64%, precision of 85%, recall of 85%, and an F1-score of 85%.

This is an open-access article under the [CC BY-SA](#) license



*Penulis Koresponden

Email: yagus.cahyadi@utdi.ac.id

Cara sitasi IEEE::

Y. Cahyadi, S. Redjeki, A. Almagribi, B. Satriani, N. Naufal, "Bidirectional Long Short-Term Memory Model for Intent Classification in Customer Service Chatbot", *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 5, no. 1, p. 296-301, Maret 2025. doi:10.30811/jaise.v5i1.6520

1. PENDAHULUAN

Layanan pelanggan merupakan elemen penting dalam memastikan kepuasan dan kepercayaan pelanggan terhadap suatu organisasi [1], [2], [3], [4]. Dalam konteks kantor pemerintahan Indonesia di luar negeri, peran layanan pelanggan semakin vital karena melibatkan penyelesaian masalah kompleks seperti pengurusan dokumen keimigrasian, ketenagakerjaan, perlindungan warga negara Indonesia, bantuan hukum, legalisasi dokumen, serta isu investasi dan perdagangan [5]. Permasalahan ini sering kali menuntut penanganan

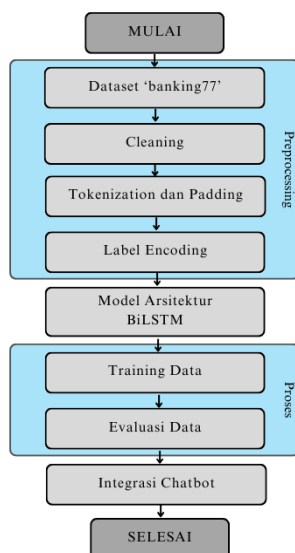
yang cepat, akurat, dan efisien. Namun, keterbatasan sumber daya manusia di bagian layanan pelanggan kerap menjadi kendala utama dalam menyediakan layanan yang memadai dan konsisten [6].

Studi sebelumnya telah mengeksplorasi penggunaan teknologi chatbot berbasis kecerdasan buatan sebagai solusi untuk meningkatkan efisiensi layanan pelanggan [7], [8], [9], [10]. Meskipun demikian, sedikit penelitian yang berfokus pada objek pelayanan pemerintah Indonesia khususnya diluar negeri. Selain itu penggunaan dataset yang generik atau sedikit. Penelitian ini mengusulkan penggunaan algoritma Bidirectional Long Short-Term Memory (Bi LSTM) untuk mengatasi *gap* tersebut, dengan memanfaatkan kemampuannya dalam memahami konteks percakapan secara mendalam [11], [12], [13]. Optimalisasi chatbot berbasis Bi LSTM diharapkan tidak hanya meningkatkan efisiensi layanan, tetapi juga mengurangi beban kerja manusia dalam konteks layanan publik yang spesifik.

2. METODE

Bagian ini menjelaskan prosedur pemodelan chatbot berbasis intent menggunakan Bi LSTM. Proses penelitian dilakukan dengan cara yang cermat dan terukur untuk memperoleh hasil yang maksimal di mana hasil inputan pelanggan bisa di jawab dengan sesuai oleh mesin chatbot. Proses penelitian tercantum pada Gambar 1.

Penelitian ini menggunakan dataset dari huggingface Banking77 yang terdiri dari data teks dan tersimpan dalam format JSONL [14]. Data terbagi menjadi 2 yaitu training data dan testing data. Statistik dataset seperti pada Tabel 1. Training dataset memiliki 10.003 sampel, rerata jumlah karakter 59,5 dan dengan 77 kategori intent. Sedangkan testing dataset memiliki 3.081 sampel, rerata jumlah karakter 54,2 dan dengan 77 kategori intent.



Gambar 1. Flowchart proses penelitian


Tabel 1. Statistik data *Banking77*

Statistik dataset	Training	Testing
Contoh data	10.003	3.081
Rerata jumlah karakter	59,5	54,2
Intent	77	77
Domain	1	1

Berikutnya data diolah atau *preprocessing*, yang mencakup proses cleaning data untuk menghilangkan karakter yang tidak diperlukan, tokenisasi untuk mengubah teks menjadi *token*, serta *padding* agar panjang setiap input seragam [15], [16]. Terakhir, dilakukan *label encoding* untuk mengubah label kategori menjadi bentuk numerik yang dapat diproses oleh model.

2.1 Arsitektur model Bi LSTM

Algoritma Bi LSTM, merupakan pengembangan dari *Long Short-Term Memory* (LSTM) [17], [18], [19], [20]. Bi LSTM bekerja dengan memproses data dalam dua arah, yaitu *forward* dan *backward*, sehingga model dapat menangkap dependensi kontekstual dalam kedua arah. Arsitektur Bi LSTM yang digunakan untuk klasifikasi teks seperti Gambar 2.



Gambar 2. Arsitektur Bi LSTM untuk klasifikasi teks

Pada Bi LSTM, terdapat dua arah propagasi, sehingga *hidden state* di setiap waktu t terdiri dari gabungan *hidden state forward* dan *backward*. Hal ini memungkinkan model untuk memahami konteks yang lebih luas dibandingkan LSTM standar.

Tabel 2 merinci parameter model Bi LSTM yang digunakan dalam penelitian ini. Embedding memiliki dimensi 256, diikuti oleh dua lapisan Bi LSTM dengan 128 dan 64 unit. Dropout 0,5 dan Regularisasi Dropout 0,5 serta 0,3 diterapkan untuk mencegah overfitting. Lapisan Dense menggunakan 128 unit dengan aktivasi ReLU dan softmax untuk klasifikasi intent. Model dioptimalkan dengan Optimizer Adam (learning rate 0,001), dilatih selama 40 Epoch, dan menggunakan Batch Size 64.

Tabel 2. Nilai parameter Bi LSTM

Parameter	Nilai
Embedding	256
Bi LSTM	128
Dropout	0,5
Bi LSTM	64
Regularisasi Dropout	0,5 dan 0,3
Dense	128 ReLu dan softmax
Optimizer model	Adam, learning rate = 0,001
Epoch	40
Batch size	64

Proses selanjutnya melakukan training data. Model dilatih untuk mengenali intent berdasarkan input teks, menggunakan teknik optimasi seperti *Adam optimizer* dan fungsi *categorical cross-entropy loss* [21], [22], [23]. Setelah proses selesai, model diuji menggunakan dataset uji untuk mengevaluasi performa dengan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* [24], [25], [26].

3. HASIL DAN PEMBAHASAN

Tabel 3 menyajikan contoh data pertanyaan dalam dua bahasa, yaitu bahasa Inggris sebagai data asli dan bahasa Indonesia sebagai hasil terjemahan. Dataset Banking77 berisi percakapan dalam domain layanan pelanggan perbankan. Data ini mencakup berbagai pertanyaan yang sering diajukan oleh pelanggan, dengan setiap pertanyaan dikategorikan ke dalam intent tertentu. Namun, penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan. Salah satunya adalah dataset yang digunakan tidak sesuai dengan data asli dari percakapan aplikasi WhatsApp, yang menjadi target utama konteks penelitian ini. Diperlukan proses ekstraksi data yang panjang dan rumit dari aplikasi WhatsApp untuk mendapatkan data yang lebih representatif. Selain itu, jika menggunakan data dari WhatsApp, diperlukan preprocessing yang lebih mendetail untuk menangani variasi bahasa dan format yang tidak terstruktur. Penggunaan dataset Banking77 dalam penelitian ini dipilih karena adanya kemiripan antara kegiatan perbankan dan layanan pelanggan, khususnya pada kantor pemerintah Indonesia di luar negeri, meskipun konteksnya tidak sepenuhnya identik.

Contoh dataset, pertanyaan seperti "*What can I do if my card still hasn't arrived after 2 weeks?*" dikategorikan ke dalam intent "*card_arrival*", yang dalam bahasa Indonesia diterjemahkan menjadi "Apa yang dapat saya lakukan jika kartu saya masih belum tiba setelah 2 minggu?" dengan intent "kartu_kedatangan". Proses penerjemahan dilakukan untuk memastikan model chatbot dapat digunakan dalam bahasa Indonesia tanpa mengurangi makna dari dataset asli.

Tabel 4 menjelaskan struktur label intent yang digunakan dalam penelitian ini. Dataset ini memiliki 77 kategori intent, dengan masing-masing intent diberi label numerik, mulai dari 0 hingga 76. Setiap intent

mewakili kebutuhan pelanggan yang spesifik dalam layanan perbankan, sehingga model yang dibangun bertujuan untuk mengklasifikasikan input pelanggan ke dalam salah satu dari 77 kategori ini secara akurat.

Tabel 3. Data pertanyaan yang sudah diterjemahkan

Bahasa	Pertanyaan	Intent
Indonesia	Apa yang dapat saya lakukan jika kartu saya masih belum tiba setelah 2 minggu?	kartu_kedatangan
Inggris	<i>What can I do if my card still hasn't arrived after 2 weeks?</i>	<i>card_arrival</i>
Indonesia	Bagaimana caranya agar kartu saya muncul di aplikasi?	menghubungkan_kartu
Inggris	<i>How can I make my card show up in the app?</i>	<i>card_linking</i>
Indonesia	Saya membeli sesuatu di luar negeri dan nilai tukar yang diterapkan salah.	pembayaran_kartu_salah_nilai_tukar
Inggris	<i>I purchased something overseas and the incorrect exchange rate was applied.</i>	<i>card_payment_wrong_exchange_rate</i>
Indonesia	Bagaimana cara mengubah PIN?	ganti_pin
Inggris	<i>How do I change the PIN?</i>	<i>change_pin</i>

Tabel 4. Data intent

Label	Intent
0	aktifkan_kartu_saya
1	batas_umur
....
75	jumlah_uang_yang_diterima_salah
76	nilai_tukar_yang_salah_untuk_penarikan_tunai


Tabel 5 menyajikan hasil pengujian model chatbot dengan jumlah data pelatihan (*training*) dan pengujian (*testing*) yang berbeda. Tiga skenario pengujian dilakukan untuk mengevaluasi performa model. Tabel 5 menunjukkan jumlah data pelatihan mempengaruhi performa model dalam mengklasifikasikan intent pelanggan. Nilai akurasi dari setiap uji coba dianalisis untuk menilai efektivitas model dalam memahami berbagai jenis pertanyaan yang diajukan pengguna.

Tabel 5. Data uji


Pengujian	Training	Testing	Accuracy	precision	recall	F1-score
Uji 1	2.471	770	73,38%	75%	73%	73%
Uji 2	4.978	1.540	79,94%	81%	80%	80%
Uji 3	10.003	3.081	84,64%	85%	85%	85%

Gambar 3 menunjukkan hubungan antara jumlah *epoch* dan akurasi model selama proses pelatihan. Akurasi meningkat secara signifikan pada tiga *epoch* pertama, menunjukkan bahwa model dengan cepat belajar pola dari data. Setelah *epoch* ke-10, akurasi mulai stabil dengan sedikit fluktuasi, menandakan bahwa model telah mencapai konvergensi. Tidak adanya peningkatan signifikan setelah beberapa *epoch* menunjukkan bahwa model telah belajar dengan baik tanpa *overfitting*.

Gambar 4 menunjukkan hubungan antara jumlah *epoch* dan *loss* model selama proses pelatihan. Grafik menunjukkan bahwa nilai *loss* mengalami penurunan yang signifikan pada beberapa *epoch* pertama, menandakan bahwa model dengan cepat belajar dan mengurangi kesalahan dalam prediksi. Setelah sekitar *epoch* ke-6, laju penurunan *loss* mulai melambat, menunjukkan bahwa model telah mencapai fase optimasi. Pada *epoch* berikutnya, *loss* semakin kecil dan akhirnya stabil mendekati nol, yang mengindikasikan bahwa model telah mencapai titik konvergensi.



Gambar 3. Model accuracy



Gambar 4. Model loss

Gambar 5 menunjukkan hasil pengujian model chatbot untuk klasifikasi intent. Dalam pengujian ini, chatbot diuji dengan tiga input berbeda, di mana model memberikan respons dengan mengklasifikasikan intent ke dalam label 75, 8, dan 49. Berdasarkan dataset Banking77, label tersebut masing-masing merujuk pada intent "jumlah_uang_yang_diterima_salah", "batalkan_transfer", dan "pin_terblokir". Hasil ini menunjukkan bahwa chatbot dapat mengidentifikasi intent pelanggan dengan tepat, sesuai dengan kategori dalam dataset yang telah digunakan dalam proses pelatihan. Namun, pengujian ini masih memiliki keterbatasan, yaitu hanya sebatas pembacaan intents oleh model tanpa melibatkan interaksi langsung dengan pengguna. Ke depan, perlu dilakukan penyempurnaan pada aplikasi sehingga pengujian dapat melibatkan pengguna secara langsung dan dilengkapi dengan kuesioner untuk mengevaluasi performa model serta kemudahan penggunaan dari perspektif pengguna.

```

CS: Hallo! Silahkan ketik pertanyaan Anda atau Ketik 'bye' untuk keluar.
Pelanggan: Saya tidak menerima jumlah uang tunai yang benar
CS: Hubungi CS terkait label 75.
Pelanggan: tolong bantu saya, ada transaksi di akun yang salah
CS: Untuk bantuan terkait label 8, silakan kunjungi portal website kami.
Pelanggan: BISAkah anda membuka blokir akun saya? saya salah memasukan PIN>
CS: Hubungi CS terkait label 49.
Pelanggan: bye
CS: Terima Kasih!

```

Gambar 5. Validasi model chatbot

4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan model Bi LSTM untuk meningkatkan efisiensi chatbot dalam layanan pelanggan. Hasil eksperimen menunjukkan akurasi sebesar 84,64%, dengan precision, recall, dan F1-score masing-masing mencapai 85%. Model menunjukkan kemampuan belajar pola data yang cepat, mencapai konvergensi pada epoch ke-10, serta efektif dalam mengklasifikasikan intent pelanggan, meskipun beberapa intent masih memiliki performa kurang optimal.

Untuk penelitian selanjutnya, dapat dilakukan penyesuaian *hyperparameter*, penambahan volume dataset, dan integrasi *pretrained embeddings* guna meningkatkan akurasi di atas 95%. Selain itu, pemanfaatan dataset asli dari data chat pelanggan untuk merefleksikan kondisi riil. Pengujian pada skenario dunia nyata juga direkomendasikan untuk memvalidasi efektivitas model dalam konteks layanan pelanggan yang beragam.

UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat Universitas Teknologi Digital Indonesia atas dukungan dan pendanaan yang diberikan dalam pelaksanaan penelitian ini.

REFERENSI

- [1] R. Santa, J. B. MacDonald, and M. Ferrer, "The role of trust in e-Government effectiveness, operational effectiveness and user satisfaction: Lessons from Saudi Arabia in e-G2B," *Gov Inf Q*, vol. 36, no. 1, pp. 39–50, Jan. 2019, doi: 10.1016/j.giq.2018.10.007.
- [2] Y. Li and H. Shang, "Service quality, perceived value, and citizens' continuous-use intention regarding e-government: Empirical evidence from China," *Information & Management*, vol. 57, no. 3, p. 103197, Apr. 2020, doi: 10.1016/j.im.2019.103197.
- [3] K. A. Prihatna, I. G. So, H. Saroso, and W. Kosasih, "What about Service Quality, Satisfaction, and Loyalty in e-Business? A Systematic Review of Literature," in *2021 International Conference on Information Management and Technology (ICIMTech)*, IEEE, Aug. 2021, pp. 767–772. doi: 10.1109/ICIMTech53080.2021.9534953.

- [4] B. Budiarno, I. B. N. Udayana, and A. Lukitaningsih, "PENGARUH KUALITAS LAYANAN, KUALITAS PRODUK TERHADAP KEPUASAN PELANGGAN DALAM MEMBENTUK LOYALITAS PELANGGAN," *Equilibrium: Jurnal Penelitian Pendidikan dan Ekonomi*, vol. 19, no. 02, pp. 226–233, Jul. 2022, doi: 10.25134/equi.v19i02.4531.
- [5] A. T. Longgarini, A. N. Shaafiyah, and B. M. Rahmaningtias, "Penanganan Pekerja Migran Indonesia Non-Prosedural dalam Perspektif Hukum Keimigrasian," *Jurnal Ilmiah Universitas Batanghari Jambi*, vol. 23, no. 2, p. 1474, Jul. 2023, doi: 10.33087/jiubj.v23i2.3110.
- [6] R. Zahara, "Pengaruh kualitas layanan terhadap loyalitas pelanggan dengan kepuasan pelanggan sebagai variabel intervening," *Jurnal Manajemen Strategi dan Aplikasi Bisnis*, vol. 3, no. 1, pp. 31–38, Jan. 2020, doi: 10.36407/jmsab.v3i1.121.
- [7] C. V. Misischia, F. Poeetze, and C. Strauss, "Chatbots in customer service: Their relevance and impact on service quality," *Procedia Comput Sci*, vol. 201, pp. 421–428, 2022, doi: 10.1016/j.procs.2022.03.055.
- [8] C.-L. Hsu and J. C.-C. Lin, "Understanding the user satisfaction and loyalty of customer service chatbots," *Journal of Retailing and Consumer Services*, vol. 71, p. 103211, Mar. 2023, doi: 10.1016/j.jretconser.2022.103211.
- [9] E. W. T. Ngai, M. C. M. Lee, M. Luo, P. S. L. Chan, and T. Liang, "An intelligent knowledge-based chatbot for customer service," *Electron Commer Res Appl*, vol. 50, p. 101098, Nov. 2021, doi: 10.1016/j.elerap.2021.101098.
- [10] S. Schanke, G. Burtch, and G. Ray, "Estimating the Impact of 'Humanizing' Customer Service Chatbots," *Information Systems Research*, vol. 32, no. 3, pp. 736–751, Sep. 2021, doi: 10.1287/isre.2021.1015.
- [11] A. B. Rakib, E. A. Rumky, A. J. Ashraf, Md. M. Hillas, and M. A. Rahman, "Mental Healthcare Chatbot Using Sequence-to-Sequence Learning and BiLSTM," 2021, pp. 378–387. doi: 10.1007/978-3-030-86993-9_34.
- [12] N. Lhasiw, T. Tanantong, and N. Sanglerdsinlapachai, "Thai Conversational Chatbot Classification Using BiLSTM and Data Augmentation," 2023, pp. 127–141. doi: 10.1007/978-981-99-7969-1_10.
- [13] P. Anki, A. Bustamam, H. S. Al-Ash, and D. Sarwinda, "High Accuracy Conversational AI Chatbot Using Deep Recurrent Neural Networks Based on BiLSTM Model," in *2020 3rd International Conference on Information and Communications Technology (ICOIACT)*, IEEE, Nov. 2020, pp. 382–387. doi: 10.1109/ICOIACT50329.2020.9332074.
- [14] I. Casanueva, T. Temčinias, D. Gerz, M. Henderson, and I. Vulić, "Efficient Intent Detection with Dual Sentence Encoders," Mar. 2020.
- [15] P. Mishra, A. Biancolillo, J. M. Roger, F. Marini, and D. N. Rutledge, "New data preprocessing trends based on ensemble of multiple preprocessing techniques," *TrAC Trends in Analytical Chemistry*, vol. 132, p. 116045, Nov. 2020, doi: 10.1016/j.trac.2020.116045.
- [16] F. Kamiran and T. Calders, "Data preprocessing techniques for classification without discrimination," *Knowl Inf Syst*, vol. 33, no. 1, pp. 1–33, Oct. 2012, doi: 10.1007/s10115-011-0463-8.
- [17] P. Suebsombut, A. Sekhari, P. Sureephong, A. Belhi, and A. Bouras, "Field Data Forecasting Using LSTM and Bi-LSTM Approaches," *Applied Sciences*, vol. 11, no. 24, p. 11820, Dec. 2021, doi: 10.3390/app112411820.
- [18] F. Shahid, A. Zameer, and M. Muneeb, "Predictions for COVID-19 with deep learning models of LSTM, GRU and Bi-LSTM," *Chaos Solitons Fractals*, vol. 140, p. 110212, Nov. 2020, doi: 10.1016/j.chaos.2020.110212.
- [19] S. Siami-Namini, N. Tavakoli, and A. S. Namin, "The Performance of LSTM and BiLSTM in Forecasting Time Series," in *2019 IEEE International Conference on Big Data (Big Data)*, IEEE, Dec. 2019, pp. 3285–3292. doi: 10.1109/BigData47090.2019.9005997.
- [20] Y. Yu, X. Si, C. Hu, and J. Zhang, "A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures," *Neural Comput*, vol. 31, no. 7, pp. 1235–1270, Jul. 2019, doi: 10.1162/neco_a_01199.
- [21] I. V. Pustokhina, D. A. Pustokhin, E. L. Lydia, P. Garg, A. Kadian, and K. Shankar, "Hyperparameter search based convolution neural network with Bi-LSTM model for intrusion detection system in multimedia big data environment," *Multimed Tools Appl*, vol. 81, no. 24, pp. 34951–34968, Oct. 2022, doi: 10.1007/s11042-021-11271-7.
- [22] N. Sutarna, C. Tjahyadi, P. Oktivasari, M. Dwiyaniti, and Tohazen, "Hyperparameter Tuning Impact on Deep Learning Bi-LSTM for Photovoltaic Power Forecasting," *Journal of Robotics and Control (JRC)*, vol. 5, no. 3, pp. 677–693, 2024, doi: 10.18196/jrc.v5i3.21120.
- [23] T. Makarovskikh and M. Abotaleb, "Hyper-parameter Tuning for Long Short-Term Memory (LSTM) Algorithm to Forecast a Disease Spreading," in *2022 VIII International Conference on Information Technology and Nanotechnology (ITNT)*, IEEE, May 2022, pp. 1–6. doi: 10.1109/ITNT55410.2022.9848654.
- [24] H. Dalianis, "Evaluation Metrics and Evaluation," in *Clinical Text Mining*, Cham: Springer International Publishing, 2018, pp. 45–53. doi: 10.1007/978-3-319-78503-5_6.
- [25] D. M. W. Powers, "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation," Oct. 2020.
- [26] R. Yacouby and D. Axman, "Probabilistic Extension of Precision, Recall, and F1 Score for More Thorough Evaluation of Classification Models," in *Proceedings of the First Workshop on Evaluation and Comparison of NLP Systems*, Stroudsburg, PA, USA: Association for Computational Linguistics, 2020, pp. 79–91. doi: 10.18653/v1/2020.eval4nlp-1.9.