

Kerangka Kerja Kecerdasan Buatan Terstruktur Sendiri untuk Pemodelan dan Analisis Emosi Mendalam di Web Sosial

A Self-Structured Artificial Intelligence Framework for Deep Emotion Modeling and Analysis on the Social Web

Muhammad Radja

Prodi Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa

radja6416@mhs.pelitabangsa.ac.id

Abstract

Social networks have enabled individuals from all walks of life to openly express their emotions and sentiments regarding current affairs, local issues and personal circumstances. Among the social webs, social media includes deep emotional expressions that reflect a variety of personalities and behaviors. A self-organizing artificial intelligence framework incorporates a new ensemble of algorithms to make this contribution. This algorithm extends the current state of natural language processing techniques, word embedding and developing self-organizing maps, especially for deep emotion modeling and analysis. The framework was empirically evaluated on anonymous conversations from online mental health support forums. The results identified emotional characteristics based on profile, emotional intensity, transition and overall latent representation across three different mental health groups in this forum. Validity and efficacy of use in real-world social media settings establish further methodological novelty of this self-regulating artificial intelligence ensemble for deep emotion.

Keywords: *Social Web, Emotion Modeling, Emotion Transition, Emotion Latent Space, Word-Embedding Emotion, Unsupervised Learning*

Abstrak

Jejaring sosial telah memungkinkan individu dari semua lapisan masyarakat untuk mengekspresikan emosi mereka secara terbuka dan sentimen sehubungan dengan urusan saat ini, masalah lokal dan keadaan pribadi. Diantara web sosial, media sosial mencakup ekspresi emosional yang mendalam yang mencerminkan berbagai kepribadian dan perilaku. Kerangka kerja kecerdasan buatan yang mengatur diri sendiri menggabungkan ansambel baru algoritma untuk membuat kontribusi ini. Algoritma ini memperluas keadaan saat ini teknik pemrosesan bahasa alami, penyematan kata, dan mengembangkan peta yang mengatur diri sendiri, khususnya untuk pemodelan dan analisis emosi yang mendalam. Kerangka tersebut dievaluasi secara empiris pada percakapan anonim dari kesehatan mental online forum dukungan. Hasilnya mengidentifikasi karakteristik emosi berdasarkan profil, intensitas emosi, transisi dan representasi laten keseluruhan di tiga kelompok kesehatan mental yang berbeda dalam hal ini forum. Validitas dan efektivitas aplikasi ke pengaturan media sosial dunia nyata menciptakan kebaruan metodologis lebih lanjut ansambel kecerdasan buatan yang mengatur diri sendiri ini untuk emosi yang dalam.

Kata kunci: Web Sosial, Pemodelan Emosi, Transisi Emosi, Ruang Laten Emosi, Emosi Penyematan Kata, Pembelajaran Tanpa Pengawasan.

Pendahuluan

Jejaring sosial telah memungkinkan individu dari semua lapisan masyarakat untuk secara terbuka mengekspresikan emosi dan sentimen mereka terkait dengan urusan terkini, masalah lokal, dan keadaan pribadi[1]. Ada berbagai psikologis, neurobiologi, dan teori sosial dalam memahami dan menafsirkan emosi [2], [3], bagaimanapun, kebenaran umum yang muncul adalah fakta bahwa emosi adalah komponen penting dari perilaku manusia. Emosi tercermin melalui tindakan, perilaku pengambilan keputusan, dan melalui komunikasi manusia sehingga memberikan satu kesempatan untuk menyelidiki secara mendalam perilaku emosional yang mengarah pada tindakan tertentu dan juga kondisi mental. Meskipun emosi manusia dikenal sebagai salah satu yang paling kompleks konsep dalam psikologi, pemahaman dan interpretasi emosi terus menjadi minat penelitian dalam teknologi, sehingga komputasi afektif dan analisis sentimen adalah kuncinya domain dalam kemajuan sistem kecerdasan buatan (AI)[4], [5].

Mengidentifikasi ekspresi emosional dari media sosial sebagian besar terfokus pada deteksi sentimen percakapan menggunakan berbagai teknik[6] [11]. Pendekatan pembelajaran dalam yang diawasi telah digunakan untuk mendeteksi skizofrenia, psikosis, delusi, dan depresi (positif,negatif) dari percakapan media sosial[3], [6], [9], [10], [12], [13]. Karena minat yang meningkat ini, memperluas sentimen ke emosi adalah topik yang muncul dalam penelitian yang berkaitan dengan komputasi afektif[7]. Kebanyakan upaya pada deteksi emosi mengambil data beranotasi atau *crowdsourced* [7], [14], [15] dan semantik untuk melatih emosi model pelacakan[9], [13]. Dalam penelitian terbaru, model *deep learning* lebih maju seperti kata-kata model *embedding* [8], algoritma pembelajaran mesin[10], [14], [16], telah digunakan untuk klasifikasi emosi. Selanjutnya, deteksi intensitas emosional telah berusaha untuk menggunakan data beranotasi[2], [17], [18] dan laporan penelitian kontemporer menggunakan metode ansambel untuk pendeteksian intensitas emosi.

Untuk mengatasi masalah ini, saya mengambil dari beberapa artikel tentang ansambel baru kecerdasan buatan penataan diri yang dapat; (1) memunculkan emosi individu dan kelompok, (2) membuat profil intensitas emosional, (3) profil transisi keadaan emosional, (4) mengembangkan representasi emosional laten tanpa pengawasan, (5) mengklasifikasikan emosi berdasarkan representasi yang dipelajari dan (6) melakukan eksplorasi granular untuk memperoleh makna kontekstual dari perilaku emosional yang teridentifikasi. Ini telah dirumuskan dan diimplementasikan sebagai kerangka kerja fungsional[6], [19] yang menunjukkan kemampuan tidak hanya untuk mendeteksi emosi tetapi juga untuk memberikan tingkat detail rinci tentang dinamika emosional di ruang media sosial. Kerangkanya adalah dievaluasi pada data percakapan anonim dari forum kesehatan *online*. Hasilnya mengkonfirmasi validitas dan efektivitas dalam deteksi dan analisis emosi di web sosial [1].


Metode Penelitian

Beberapa metode yang digunakan terkait dengan masalah ansambel baru kecerdasan buatan dari beberapa artikel. Metode pengenalan emosi multibahasa berdasarkan fitur akustik yang dinormalisasi menggunakan CRNN [13], [14], menggabungkan *FastText* dan *Glove Word Embedding* untuk deteksi teks ujaran kebencian dan menyinggung[8], [20] dan deep learning yang mengacu pada penggunaan jaringan saraf tiruan (DNN)[5], [9], [21].

Pengenalan emosi multibahasa berdasarkan fitur akustik yang dinormalisasi menggunakan CRNN

Penelitian ini menggunakan 2 jurnal yang terkait dengan metode CNN atau CRNN. Metode yang diusulkan didasarkan pada metode pengenalan emosi ucapan berbasis convolutional recurrent neural network (CRNN), di mana fitur akustik dihitung bingkai demi bingkai, dan matriks dua dimensi (2D) (jumlah fitur akustik \times jumlah bingkai) digunakan sebagai input ke CRNN. Metode yang diusulkan menggabungkan fitur akustik dari ucapan

emosional dan ucapan yang disintesis dengan memperluas jumlah dimensi masukan menjadi tiga[13].



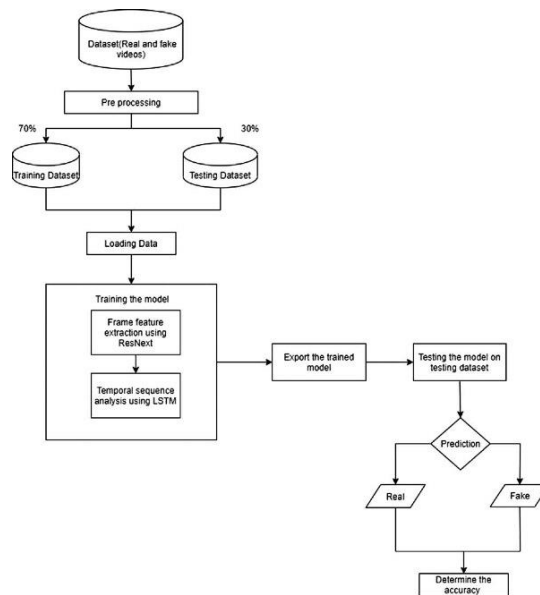
Gambar 1. Network structure (diadaptasi dari [13])

Pada lapisan input CRNN, konvolusi 3D dilakukan antara dimensi fitur akustik, arah waktu, dan antara ucapan emosional dan sintesis. Akibatnya, filter konvolusional dilatih secara otomatis untuk menghitung fitur akustik yang hanya menekankan informasi emosional terlepas dari bahasanya.

Setelah membangun lima lapisan jaringan saraf convolutional (CNN) 3D, dua lapisan memori jangka pendek (LSTM) panjang digunakan untuk melatih struktur temporal, dan pengenalan emosi dilakukan menggunakan perhatian dan lapisan yang terhubung sepenuhnya.

Dalam jaringan, CNN 3D mengekstraksi fitur akustik yang bebas bahasa, sementara jaringan lain mengenali kategori emosional. Jaringan ini terhubung secara seri, dan semua jaringan dilatih secara bersamaan. Ini berarti bahwa CNN 3D (dan jaringan lain) dilatih menggunakan kriteria "maksimisasi tingkat pengakuan". Akibatnya, akurasi pengenalan diharapkan meningkat.

Metode CNN menggunakan bahasa *Python* dengan kerangka yang disajikan oleh bahasa ini yaitu *PyTorch* yang juga berbasis bahasa *Jupyter notebook* dan *Panda*. Pada artikel [14] disajikan *Block diagram* tentang proses struktur *dataset* yang bisa dilihat pada Gambar 2.



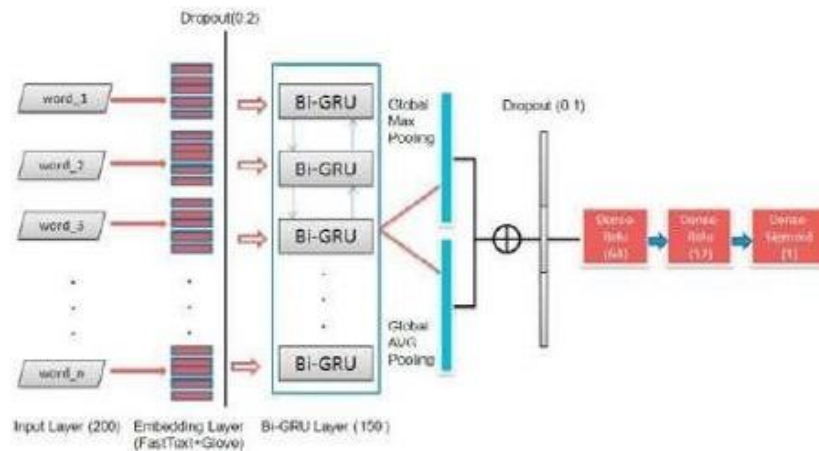
Gambar 2. Block Diagram

Algoritma struktur dataset adalah; (1) Kumpulan dataset, (2) Pra-proses video menjadi bingkai dan pangkas wajah, (3) Kembangkan model menggunakan CNN dan LSTM, (4) Latih model dengan set data yang dikumpulkan, (5) Uji model yang dikembangkan dengan set data uji, (6) Buat prediksi pada video tertentu, (7) Hitung keakuratan model, (8) Menampilkan hasil klasifikasi video dan hasil akurasi, (9) Akhir.

Menggabungkan *FastText* dan *Glove Word Embedding* untuk deteksi teks ujaran kebencian dan menyinggung

Penelitian ini menggunakan 2 artikel yang terkait dengan metode ini. Berdasarkan ulasan tentang fitur dan pengklasifikasi terkemuka yang digunakan untuk klasifikasi teks, di artikel ini menjelaskan proses untuk mendeteksi konten teks bahasa Inggris yang tidak pantas. Pendekatan kami didasarkan pada model klasifikasi pembelajaran mendalam (BiGRU) dan kombinasi teknik penyisipan kata (*Glove dan FastText*) sebagai fitur[8], [20].

Model BiGRU-Glove-FT yang diusulkan dari artikel[8], [20] mengambil teks input dan menampilkan probabilitas bahwa teks input ini termasuk kelas yang tidak pantas (Menyerang atau Tidak Menyinggung). Teks input dimasukkan ke dalam model dalam bentuk gabungan dari matriks penyematan kata "*Glove dan FastText*". Model BiGRU-Glove-FT terdiri dari delapan lapisan berurutan— (a) Lapisan Input, (b) Lapisan Penyematan, (c) Lapisan SpatialDropout, (d) Lapisan Dua Arah (GRU), (e) Agregasi Rata-Rata Global 1D dan Maks Global Lapisan 1D agregasi, (f) Lapisan fusi, (g) Lapisan putus sekolah, dan terakhir (h) Lapisan padat seperti yang ditunjukkan pada Gambar 3.



Gambar 3. Model Bi-GRU dengan kombinasi penyematan FastText dan Glove (diadaptasi dari[8]).

Dibawah ini terdapat tabel yang menyajikan hasil dari metode yang berdasarkan artikel yang terkait.

Tabel 1. *OLID Dataset*

Classes	Train	Test	Total tweets
Offensive	4400	240	4640
Not Offensive	8840	620	9460
	13420	860	14100

Tabel 2. *Hate Speech Dataset*

Normal	11213	2817	53851
Abusive	21781	5369	27150
Spam	43003	10848	14030
Hateful	3999	966	4965
	79996	20000	99996

Tabel 3. Hasil akhir dari model pembelajaran mesin dasar klasik, untuk kumpulan data OLID. Angka tebal mewakili skor terbaik dan garis bawah mewakili skor terbaik kedua (diadaptasi dari[8]).

OLiD Dataset (2 classes)											

Models	Acc	Not			Off			Weighted Average			F1-Macro
		P	R	F1	P	R	F1	P	R	F1	
Models on Count Vectors											
Naive bayes (NB)	0.80	0.84	0.89	0.86	0.66	0.57	0.61	0.79	0.80	0.79	0.74
Logistic Regression (LR)	0.81	0.83	0.93	0.87	0.72	0.50	0.59	0.80	0.81	0.79	0.73
Support Vector Machine (SVM)	0.78	0.77	0.98	0.86	0.81	0.27	0.40	0.78	0.78	0.73	0.63
XGBoost (XGB)	0.79	0.78	0.98	0.87	0.85	0.29	0.43	0.80	0.79	0.75	0.65
Random Forest (RF)	0.81	0.82	0.94	0.88	0.75	0.48	0.59	0.80	0.81	0.80	0.73
Models on Word Level TF IDF Vectors											
Naive Bayes (NB)	0.78	0.77	0.99	0.86	0.89	0.23	0.36	0.80	0.78	0.72	0.61
Logistic Regression (LR)	0.82	0.82	0.96	0.88	0.82	0.44	0.57	0.82	0.82	0.80	0.73
Support Vector Machine (SVM)	0.81	0.82	0.94	0.88	0.75	0.48	0.59	0.80	0.81	0.80	0.73
XGBoost (XGB)	0.79	0.78	0.98	0.87	0.87	0.28	0.42	0.80	0.79	0.74	0.65
Random Forest (RF)	0.81	0.82	0.94	0.88	0.75	0.48	0.59	0.80	0.81	0.80	0.73
Models on Ngram Level TF IDF Vectors											
Naive bayes (NB)	0.75	0.75	0.96	0.85	0.66	0.18	0.29	0.73	0.75	0.69	0.57
Logistic Regression (LR)	0.74	0.76	0.95	0.84	0.63	0.20	0.31	0.72	0.74	0.69	0.58
Support Vector Machine (SVM)	0.74	0.76	0.87	0.81	0.47	0.30	0.37	0.68	0.71	0.69	0.59
XGBoost (XGB)	0.73	0.73	0.99	0.84	0.70	0.06	0.11	0.72	0.73	0.64	0.47
Random Forest (RF)	0.72	0.76	0.93	0.84	0.58	0.25	0.35	0.71	0.74	0.70	0.59
Models on Character Level TF IDF Vectors											
Naive bayes (NB)	0.77	0.76	0.98	0.86	0.81	0.22	0.34	0.78	0.77	0.71	0.60
Logistic Regression (LR)	0.81	0.81	0.95	0.88	0.77	0.44	0.56	0.80	0.81	0.79	0.72
Support Vector Machine (SVM)	0.81	0.82	0.92	0.87	0.69	0.46	0.56	0.78	0.79	0.78	0.71
XGBoost (XGB)	0.79	0.80	0.95	0.86	0.73	0.38	0.49	0.78	0.79	0.76	0.68
Random Forest (RF)	0.78	0.78	0.98	0.87	0.85	0.28	0.42	0.80	0.79	0.74	0.65
BiLSTM (Marcos Zampieri,2019)	-	0.83	0.95	0.89	0.81	0.48	0.60	0.82	0.82	0.81	0.75
SVM (Marcos Zampieri,2019)	-	0.80	0.92	0.86	0.66	0.43	0.52	0.76	0.78	0.76	0.69

Deep learning yang mengacu pada penggunaan jaringan saraf tiruan (DNN)

Penelitian ini menggunakan 3 artikel yang terkait dengan metode ini. Model *Deep Neural Network* digunakan untuk melatih dataset [5], [21]. Algoritma *Convolution Neural Network* (CNN) adalah salah satu teknik pembelajaran mesin yang terbukti untuk membangun model jaringan saraf untuk kumpulan data gambar. Kerangka kerja jaringan saraf dikembangkan dan diuji dengan parameter yang berbeda seperti akurasi data kereta jaringan, akurasi data uji model, kerugian pelatihan, kerugian pengujian atau validasi, dll. Jaringan saraf yang sangat dalam digunakan untuk pengenalan wajah.

Pada artikel [9], telah dilakukan survei satu set data klinis untuk 458 peserta dari spesialis dan layanan psikiatri komunitas di Australia, Selandia Baru, dan Jepang diekstrak dari alat berbasis web khusus yang disebut Psynary. Dataset yang digunakan dalam artikel ini adalah dataset open source fer2013. Dataset ini terdiri dari 35887 citra grayscale, dimana setiap citra merupakan citra wajah berukuran 48×48 dengan berbagai emosi. Di Tabel 3. terdapat hasil dari pengelompokan atau label dataset dari hasil survei.

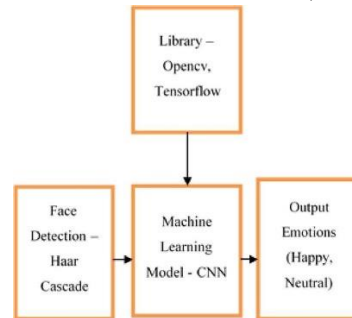
Tabel 3. fer2013 dataset

Tipe Emosi	Label	Jumlah Gambar
Marah	0	4593
Jijik	1	547
Takut	2	5121
Senang	3	8989
Sedih	4	6077
Kejutan	5	4002
Netral	6	6198

Menurut survei dari artikel [9], diterangkan bahwa tidak ada desain atau kerangka seperti itu untuk memperkirakan ekspresi atau tingkat emosi manusia. Serangkaian penelitian dapat ditemukan, bahwa dengan mengumpulkan berbagai informasi organ tubuh manusia, seperti detak jantung, tekanan darah dll, dan sentimen pikiran dapat dianalisis, diuji pada database publik dari Audio / *Visual Emotion Challenge* 2014 yang disetel untuk lebih fokus pada depresi. Hasilnya mengungguli semua metode lain yang tersedia di database yang sama. Contoh gambar emosi wajah ditampilkan pada Gambar 4. Arsitektur sistem dari desain ditampilkan pada Gambar 5.



Gambar 4. Emosi wajah



Gambar 5. Arsitektur sistem yang diusulkan.

Kesimpulan

Pada artikel ini yang disusun dari beberapa referensi yang mendukung dalam pembuatan, saya mengetahui tentang kerangka kecerdasan buatan yang mengatasi keterbatasan tersebut memodelkan dan mengidentifikasi variasi emosi yang diekspresikan dalam jejaring sosial. Kerangka kerja ini menggunakan ansambel teknik NLP dan AI untuk mengekstrak emosi individu dan kelompok dari sosial percakapan media untuk menghasilkan profil intensitas dan transisi keadaan emosional dengan menggunakan teori ilmiah tentang emosi sebagai dasar. Hasil dari artikel yang saya susun menunjukkan bahwa framework memiliki kemampuan untuk memperoleh emosi yang dalam dan transisi serta ruang tersembunyi yang menambah nilai dibandingkan dengan sentimen tradisional atau banyak digunakan deteksi dan analisis. Ini memberikan kesempatan untuk saya untuk mengeksplorasi dinamika emosi dalam digital ruang sehingga bisa mengimplementasikan penelitian ini dalam memodelkan perilaku yang lebih rinci dan kompleks jaringan sosial. Validitas dan efektivitas aplikasi ke pengaturan media sosial dunia nyata menciptakan kebaruan metodologis lebih lanjut ansambel kecerdasan buatan yang mengatur diri sendiri ini untuk emosi yang dalam.

Daftar Pustaka

- [1] A. Adikari, G. Gamage, D. de Silva, N. Mills, S. M. J. Wong, and D. Alahakoon, "A self structuring artificial intelligence framework for deep emotions modeling and analysis on the social web," *Future Generation Computer Systems*, vol. 116, pp. 302–315, Mar. 2021, doi: 10.1016/j.future.2020.10.028.
- [2] R. A. Adams, P. Vincent, D. Benrimoh, K. J. Friston, and T. Parr, "Everything is connected: Inference and attractors in delusions," *Schizophr Res*, vol. 245, pp. 5–22, Jul. 2022, doi: 10.1016/j.schres.2021.07.032.
- [3] J. Haarsma, P. Kok, and M. Browning, "The promise of layer-specific neuroimaging for testing predictive coding theories of psychosis," *Schizophr Res*, vol. 245, pp. 68–76, Jul. 2022, doi: 10.1016/j.schres.2020.10.009.
- [4] G. Siemens *et al.*, "Human and artificial cognition," *Computers and Education: Artificial Intelligence*, p. 100107, Nov. 2022, doi: 10.1016/j.caeai.2022.100107.

- [5] J. A. Cortes-Briones, N. I. Tapia-Rivas, D. C. D'Souza, and P. A. Estevez, "Going deep into schizophrenia with artificial intelligence," *Schizophr Res*, vol. 245, pp. 122–140, Jul. 2022, doi: 10.1016/j.schres.2021.05.018.
- [6] T. Erdmann and C. Mathys, "A generative framework for the study of delusions," *Schizophr Res*, vol. 245, pp. 42–49, Jul. 2022, doi: 10.1016/j.schres.2020.11.048.
- [7] W. Froelich and R. Deja, "Selection a group of features based on machine learning algorithms to simplify psycho-technical examination," *Procedia Comput Sci*, vol. 207, pp. 319–326, 2022, doi: 10.1016/j.procs.2022.09.065.
- [8] N. Badri, F. Koubi, and A. H. Chaibi, "Combining FastText and Glove Word Embedding for Offensive and Hate speech Text Detection," *Procedia Comput Sci*, vol. 207, pp. 769–778, 2022, doi: 10.1016/j.procs.2022.09.132.
- [9] D. Nixon, V. V. Mallappa, V. Petli, S. HosgurMath, and S. Kiran K, "A novel AI therapy for depression counseling using face emotion techniques," *Global Transitions Proceedings*, vol. 3, no. 1, pp. 190–194, Jun. 2022, doi: 10.1016/j.gltp.2022.03.008.
- [10] L. L. Zeng *et al.*, "Multi-Site Diagnostic Classification of Schizophrenia Using Discriminant Deep Learning with Functional Connectivity MRI," *EBioMedicine*, vol. 30, pp. 74–85, Apr. 2018, doi: 10.1016/j.ebiom.2018.03.017.
- [11] J. Saint, Y. Fan, D. Gašević, and A. Pardo, "Temporally-focused analytics of self-regulated learning: A systematic review of literature," *Computers and Education: Artificial Intelligence*, vol. 3. Elsevier B.V., Jan. 01, 2022. doi: 10.1016/j.caeai.2022.100060.
- [12] G. Shen *et al.*, "Depression Detection via Harvesting Social Media: A Multimodal Dictionary Learning Solution," 2017. [Online]. Available: <http://tinyurl.com/zrnw5j>.
- [13] M. Suzuki and J. Qi, "Improvement of multilingual emotion recognition method based on normalized acoustic features using CRNN," *Procedia Comput Sci*, vol. 207, pp. 684–691, 2022, doi: 10.1016/j.procs.2022.09.123.
- [14] V. V. V. N. S. Vamsi *et al.*, "Deepfake detection in digital media forensics," *Global Transitions Proceedings*, vol. 3, no. 1, pp. 74–79, Jun. 2022, doi: 10.1016/j.gltp.2022.04.017.
- [15] P. Kuppens and P. Verduyn, "Emotion dynamics," *Current Opinion in Psychology*, vol. 17. Elsevier B.V., pp. 22–26, Oct. 01, 2017. doi: 10.1016/j.copsyc.2017.06.004.
- [16] L. Zhang, S. Wang, and B. Liu, "Deep learning for sentiment analysis: A survey," *Wiley Interdiscip Rev Data Min Knowl Discov*, vol. 8, no. 4, Jul. 2018, doi: 10.1002/widm.1253.
- [17] A. Bhutoria, "Personalized education and Artificial Intelligence in the United States, China, and India: A systematic review using a Human-In-The-Loop model," *Computers and Education: Artificial Intelligence*, vol. 3, Jan. 2022, doi: 10.1016/j.caeai.2022.100068.
- [18] A. Mehrabian, "Pleasure-Arousal-Dominance: A General Framework for Describing and Measuring Individual Differences in Temperament," 1996.

- [19] A. J. Vidanaralage, A. T. Dharmaratne, and S. Haque, “AI-based multidisciplinary framework to assess the impact of gamified video-based learning through schema and emotion analysis,” *Computers and Education: Artificial Intelligence*, vol. 3, Nov. 2022, doi: 10.1016/j.caeai.2022.100109.
- [20] I. N. Khasanah, “Sentiment Classification Using fastText Embedding and Deep Learning Model,” in *Procedia CIRP*, 2021, vol. 189, pp. 343–350. doi: 10.1016/j.procs.2021.05.103.
- [21] O. Araque, I. Corcuera-Platas, J. F. Sánchez-Rada, and C. A. Iglesias, “Enhancing deep learning sentiment analysis with ensemble techniques in social applications,” *Expert Syst Appl*, vol. 77, pp. 236–246, Jul. 2017, doi: 10.1016/j.eswa.2017.02.002.