



Implementasi Convolutional Neural Network Berbasis Word Embedding untuk Klasifikasi Pertanyaan Chatbot

Rayhan Pratama^{1*}, Irvan²

^{1,2}Program Studi Sistem Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia
Email: ^{1*}agarayhan123@gmail.com, ²irvan@umsu.ac.id

Abstrak

Chatbot merupakan sistem percakapan berbasis kecerdasan buatan yang mampu memberikan respons otomatis terhadap pertanyaan pengguna secara real-time. Penelitian ini mengimplementasikan metode Convolutional Neural Network (CNN) yang diintegrasikan dengan Word Embedding berbasis Word2Vec untuk mengklasifikasikan pertanyaan pada chatbot Nova AI yang dikembangkan khusus bagi mahasiswa Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) Universitas Muhammadiyah Sumatera Utara (UMSU). Dataset terdiri dari 619 pertanyaan dalam bahasa Indonesia yang dikategorikan ke dalam enam kelas intent: dekan, dosen, fakultas, kaprodi, sapaan, dan UKT, dengan pembagian 495 data latih (79,97%) dan 124 data uji (20,03%). Pipeline praproses teks mencakup case folding, tokenisasi, representasi Word2Vec berdimensi 100, pengindeksan kata, dan padding dengan max_len=10. Arsitektur CNN yang dibangun terdiri atas lapisan Embedding, Conv1D (64 filter, kernel 3, ReLU), GlobalMaxPooling1D, Dense 64 unit ReLU, dan Dense output 6 unit Softmax. Model dilatih selama 20 epoch menggunakan optimizer Adam dengan learning rate 0,001 dan fungsi loss Sparse Categorical Crossentropy. Hasil evaluasi menunjukkan akurasi model sebesar 99,19%, dengan satu kesalahan klasifikasi pada intent kaprodi yang teridentifikasi sebagai dekan. Pengujian sistem Nova AI berbasis Streamlit menghasilkan tingkat keberhasilan 83,33% (25 dari 30 skenario pengujian). Penelitian ini membuktikan bahwa kombinasi CNN dan Word Embedding mampu mengklasifikasikan intent chatbot dengan akurasi tinggi dan dapat diimplementasikan dalam aplikasi nyata berbasis web.

Kata Kunci: Convolutional Neural Network, Word Embedding, Word2Vec, Chatbot, Klasifikasi Intent, Natural Language Processing.

PENDAHULUAN

Perkembangan teknologi kecerdasan buatan (Artificial Intelligence/AI) yang pesat telah mendorong adopsi luas chatbot di berbagai sektor, termasuk pendidikan tinggi. Chatbot merupakan program komputer yang dirancang untuk mensimulasikan percakapan manusia dan memberikan respons otomatis atas pertanyaan pengguna tanpa intervensi manusia secara langsung (Adamopoulou & Moussiades, 2020). Dalam konteks perguruan tinggi, kebutuhan akan akses informasi yang cepat, akurat, dan tersedia sepanjang waktu terkait layanan akademik—seperti informasi pimpinan fakultas, dosen pengajar, ketua program studi, biaya pendidikan (UKT), serta profil institusi—menjadi sangat krusial bagi mahasiswa.

Inti dari sistem chatbot modern adalah kemampuan memahami dan mengklasifikasikan maksud (intent) pengguna dari teks pertanyaan yang diajukan. Natural Language Processing (NLP) menyediakan fondasi teknis untuk tugas ini, dengan metode klasifikasi teks yang terus berkembang dari pendekatan berbasis aturan menuju model deep learning yang lebih adaptif (Jurafsky & Martin, 2020; Minaee et al., 2022). Kim (2014) memperkenalkan penggunaan Convolutional Neural Network (CNN) untuk klasifikasi kalimat menggunakan pre-trained word vectors dan membuktikan bahwa CNN dengan arsitektur sederhana mampu mengungguli berbagai model yang lebih kompleks pada sejumlah benchmark teks. Mikolov et al. (2013) mengembangkan Word2Vec sebagai metode representasi kata berbasis embedding yang mampu menangkap hubungan semantik dan sintaktis antar kata dalam ruang vektor berdimensi rendah.

Di ranah chatbot pendidikan, Smutny & Schreiberova (2020) meneliti pemanfaatan chatbot berbasis AI dalam lingkungan pendidikan dan menemukan bahwa chatbot yang dilengkapi kemampuan pemahaman bahasa alami mampu meningkatkan aksesibilitas informasi akademik secara signifikan. Wang & Li (2022) menunjukkan bahwa CNN mampu mencapai akurasi 98,7% untuk klasifikasi teks dengan


memanfaatkan representasi fitur dari lapisan konvolusi, sementara Wang et al. (2020) mengadaptasi pendekatan serupa untuk klasifikasi teks pendek dan memperoleh F1-score 0,94. Yogatama et al. (2017) dan Zhang & LeCun (2016) memperkuat temuan bahwa deep learning, khususnya CNN, secara konsisten mengungguli metode klasifikasi teks konvensional. Dalam konteks UMSU, penelitian yang dilakukan oleh Hadikosyah & Hasibuan (2026) menggunakan Support Vector Machine dengan TF-IDF untuk menganalisis sentimen publik terhadap kenaikan UKT di Platform X menunjukkan pentingnya kemampuan pemrosesan teks berbasis NLP dalam menganalisis dan memahami informasi yang berkaitan dengan layanan akademik universitas, termasuk isu UKT yang menjadi salah satu topik utama dalam chatbot Nova AI.

Meskipun berbagai metode klasifikasi teks telah diteliti, aplikasi spesifik CNN berbasis Word Embedding untuk klasifikasi intent pertanyaan pada chatbot informasi akademik perguruan tinggi di Indonesia masih terbatas. Penelitian ini mengisi kesenjangan tersebut dengan mengimplementasikan CNN yang dipadukan dengan Word Embedding Word2Vec untuk mengklasifikasikan pertanyaan yang masuk ke chatbot Nova AI—sebuah sistem chatbot yang dikembangkan khusus untuk melayani kebutuhan informasi mahasiswa FIKTI UMSU dalam enam kategori intent.

Tujuan penelitian ini adalah: (1) mengimplementasikan model CNN berbasis Word Embedding untuk mengklasifikasikan enam kategori intent pertanyaan chatbot; (2) mengevaluasi performa model menggunakan metrik akurasi, presisi, recall, dan F1-score; (3) mengintegrasikan model klasifikasi dengan knowledge base untuk menghasilkan respons chatbot yang akurat; dan (4) menguji kelayakan sistem Nova AI secara keseluruhan dalam skenario penggunaan nyata.

METODE

Alur kerja sistem klasifikasi pertanyaan chatbot Nova AI ditunjukkan pada Gambar 1. Sistem menerima input berupa pertanyaan pengguna, kemudian melalui tahap praproses yang mencakup tokenizing, case folding, stopword removal, dan stemming. Hasil praproses selanjutnya direpresentasikan menggunakan word embedding sebelum diklasifikasikan oleh model CNN untuk menghasilkan output berupa kategori pertanyaan yang sesuai.



Gambar 1. Diagram Alir Metodologi Penelitian

Pengumpulan Data

Dataset penelitian terdiri dari 619 pertanyaan dalam bahasa Indonesia yang dikumpulkan dan dianotasi secara manual ke dalam enam kelas intent yang merepresentasikan kebutuhan informasi utama mahasiswa FIKTI UMSU. Distribusi data disajikan pada Tabel 1.

Tabel 1. Distribusi Dataset per Kelas Intent

Intent	Data Latih	Data Uji	Total
Dekan	82	20	102
Dosen	82	20	102
Fakultas	85	21	106
Kaprodi	81	21	102
Sapaan	82	21	103
UKT	83	21	104
Total	495	124	619

Praproses Teks

Pipeline praproses teks terdiri dari lima tahap berurutan yang mengubah pertanyaan mentah berbentuk teks menjadi representasi vektor yang dapat diproses oleh model CNN.


Case folding mengonversi seluruh karakter teks ke huruf kecil untuk menghilangkan inkonsistensi kapitalisasi. Tokenisasi memisahkan kalimat menjadi unit kata individual (token). Representasi Word Embedding menggunakan model Word2Vec (Mikolov et al., 2013) dengan metode Continuous Bag-of-Words (CBOW) yang menghasilkan vektor kata berdimensi 100 dan mampu menangkap kemiripan semantik antar kata. Word indexing memetakan setiap token ke bilangan bulat unik berdasarkan frekuensi kemunculannya. Padding menyeragamkan panjang sekuens indeks menjadi $\text{max_len} = 10$ dengan menambahkan nilai 0 di akhir sekuens yang lebih pendek.

Tabel 2. Contoh Tahapan Praproses Teks

Tahap	Hasil
Input Awal	"Siapa Kaprodi di FIKTI?"
Case Folding	"siapa kaprodi di fikti"
Tokenisasi	["siapa", "kaprodi", "di", "fikti"]
Word Indexing	[1, 7, 17, 2]
Padding (max=10)	[1, 7, 17, 2, 0, 0, 0, 0, 0, 0]

Arsitektur Model CNN

Model CNN yang dibangun terdiri dari lima lapisan berurutan yang dirancang untuk mengekstraksi fitur semantik dari representasi vektor kata masukan.



Gambar 2. Arsitektur Model CNN untuk Klasifikasi Intent

Tabel 3. Detail Arsitektur Model CNN

Layer	Output Shape	Aktivasi	Parameter
Embedding (233×100)	(None, 233, 100)	-	23.300
Conv1D (64 filter, k=3)	(None, 231, 64)	ReLU	19.264
GlobalMaxPooling1D	(None, 64)	-	0
Dense (64 unit)	(None, 64)	ReLU	4.160
Dense output (6 unit)	(None, 6)	Softmax	390
Total Parameter			47.114

Parameter Pelatihan

Tabel 4. Parameter Pelatihan Model CNN

Parameter	Nilai
Optimizer	Adam
Learning Rate	0,001
Batch Size	32
Epoch	20
Fungsi Loss	Sparse Categorical Crossentropy
Metrik Evaluasi	Accuracy
Confidence Threshold	$\geq 0,70$

Evaluasi Model

Performa model dievaluasi menggunakan akurasi keseluruhan, presisi, recall, dan F1-score per kelas (Powers, 2011), serta confusion matrix untuk mengidentifikasi pola kesalahan klasifikasi. Presisi mengukur proporsi prediksi positif yang benar, recall mengukur proporsi sampel positif yang berhasil diidentifikasi, dan F1-score merupakan rata-rata harmonik dari keduanya.


Implementasi Sistem

Sistem Nova AI diimplementasikan sebagai aplikasi web menggunakan framework Streamlit berbasis Python. Sistem mencakup modul praproses, modul inferensi CNN, modul knowledge base, dan antarmuka pengguna. Pada saat inferensi, pertanyaan pengguna melewati pipeline praproses yang sama seperti saat pelatihan, kemudian model CNN menghasilkan vektor probabilitas untuk enam kelas intent. Jika nilai kepercayaan (confidence) tertinggi $\geq 0,70$, sistem mengembalikan respons dari knowledge base sesuai intent yang diprediksi; jika $< 0,70$, sistem mengembalikan respons default: "Maaf, Nova belum memahami pertanyaan tersebut."


HASIL DAN PEMBAHASAN

Implementasi Sistem Nova AI


Nova AI berhasil diimplementasikan sebagai aplikasi web berbasis Streamlit yang dapat diakses melalui peramban web. Antarmuka pengguna dirancang dengan tampilan sederhana dan intuitif, memungkinkan mahasiswa mengajukan pertanyaan secara natural. Sistem mengintegrasikan model CNN yang telah dilatih dengan knowledge base yang berisi informasi terkait enam kategori intent.



Gambar 3. Tampilan Antarmuka Utama Nova AI



Gambar 4. Contoh Sesi Interaksi Pengguna dengan Nova AI



Gambar 5. Alur Kerja Sistem Nova AI dari Input Pengguna hingga Respons


Hasil Praproses Teks

Pipeline praproses teks berhasil mengubah pertanyaan mentah berbahasa Indonesia menjadi representasi numerik yang siap diproses oleh model CNN. Pada contoh pertanyaan "Siapa Kaprodi di FIKTI?", setelah melalui seluruh tahap praproses diperoleh representasi akhir berupa: [1, 7, 17, 2, 0, 0, 0, 0, 0, 0], dengan panjang sekuens seragam 10. Nilai nol di posisi 5–10 merupakan hasil padding yang memastikan keseragaman dimensi masukan bagi seluruh sampel dalam dataset.

Word2Vec CBOW berhasil merepresentasikan setiap kata dalam ruang vektor 100 dimensi, di mana kata-kata dengan konteks yang mirip memiliki vektor yang berdekatan. Ukuran kosakata (vocabulary size) yang dihasilkan adalah 233, yang mencerminkan keragaman leksikal dalam dataset 619 pertanyaan berdomen terbatas.

Pelatihan dan Kurva Konvergensi Model

Model CNN dilatih selama 20 epoch dengan batch size 32 menggunakan optimizer Adam. Gambar 6 menampilkan kurva akurasi pelatihan dan loss selama proses training. Model menunjukkan konvergensi yang baik dan stabil, dengan akurasi pelatihan mencapai nilai mendekati 1,0 dan loss yang menurun secara monoton sejak epoch awal. Tidak terdapat indikasi overfitting yang signifikan, yang menunjukkan bahwa arsitektur CNN dan ukuran dataset yang digunakan cukup seimbang.



Gambar 6. Kurva Akurasi dan Loss Selama 20 Epoch Pelatihan

Evaluasi Model CNN

Hasil evaluasi model CNN pada 124 sampel data uji disajikan pada Tabel 5. Model mencapai akurasi keseluruhan 99,19%, yang merupakan performa sangat tinggi untuk tugas klasifikasi enam kelas.

Tabel 5. Hasil Evaluasi Model CNN per Kelas Intent

Intent	Presisi	Recall	F1-Score	Support
Dekan	0,95	1,00	0,97	20
Dosen	1,00	1,00	1,00	20
Fakultas	1,00	1,00	1,00	21
Kaprodi	1,00	0,95	0,97	21
Sapaan	1,00	1,00	1,00	21
UKT	1,00	1,00	1,00	21
Akurasi Keseluruhan			0,99	124

Confusion matrix pada Tabel 6 menunjukkan bahwa dari 124 sampel uji, 123 diklasifikasikan dengan benar dan hanya 1 kesalahan terjadi, yaitu satu sampel intent kaprodi diklasifikasikan sebagai dekan. Hal ini menyebabkan nilai presisi kelas dekan sebesar 0,95 (20/21 prediksi dekan benar) dan recall kelas kaprodi sebesar 0,95 (20/21 sampel kaprodi teridentifikasi benar).

Tabel 6. Confusion Matrix Hasil Prediksi Model CNN

Aktual \ Prediksi	Dekan	Dosen	Fakultas	Kaprodi	Sapaan	UKT
Dekan	20	0	0	0	0	0
Dosen	0	20	0	0	0	0
Fakultas	0	0	21	0	0	0
Kaprodi	1	0	0	20	0	0
Sapaan	0	0	0	0	21	0
UKT	0	0	0	0	0	21


Kesalahan klasifikasi yang terjadi antara intent kaprodi dan dekan dapat dijelaskan dari perspektif semantik. Kedua intent tersebut sama-sama berkaitan dengan pejabat struktural di tingkat fakultas dan program studi, sehingga beberapa pertanyaan yang berkaitan dengan kaprodi mungkin mengandung

konteks kata yang tumpang-tindih dengan pertanyaan seputar dekan. Hal ini konsisten dengan temuan Young et al. (2018) yang menyatakan bahwa model deep learning cenderung mengalami kesulitan pada kelas-kelas yang memiliki hubungan semantik erat. Memperluas dan mendiversifikasi dataset untuk kedua kelas ini diperkirakan dapat mengatasi permasalahan tersebut.


Dibandingkan dengan penelitian terdahulu, model CNN pada penelitian ini mencapai akurasi yang sangat kompetitif. Wang & Li (2022) melaporkan akurasi 98,7% pada klasifikasi teks berita berbahasa Mandarin menggunakan CNN, sementara Wang et al. (2020) memperoleh F1-score 0,94 untuk klasifikasi teks pendek. Model pada penelitian ini (akurasi 99,19%) menunjukkan bahwa CNN dengan Word Embedding efektif tidak hanya untuk bahasa Inggris, tetapi juga untuk teks pendek berbahasa Indonesia dalam domain aplikasi yang terbatas (domain-specific).

Klasifikasi Intent dan Integrasi Knowledge Base


Sistem Nova AI mengintegrasikan model CNN dengan knowledge base yang berisi informasi terstruktur untuk setiap kategori intent. Ketika model mengklasifikasikan pertanyaan ke suatu intent, sistem mengambil respons yang relevan dari knowledge base yang sesuai.




Gambar 7. Contoh Chatbot Nova AI Menjawab Pertanyaan tentang Dekan



Gambar 8. Contoh Pengujian dengan Intent yang Terklasifikasi Benar



Gambar 9. Contoh Pengujian dengan Intent yang Terklasifikasi Tidak Tepat



Gambar 10. Contoh Respons untuk Pertanyaan di Luar Cakupan Knowledge Base

Pengujian Sistem

Pengujian sistem dilakukan menggunakan 30 skenario pertanyaan yang bervariasi, mencakup semua kategori intent serta pertanyaan di luar cakupan sistem (out-of-scope). Pertanyaan dengan nilai kepercayaan $< 0,70$ menghasilkan respons: "Maaf, Nova belum memahami pertanyaan tersebut." yang merupakan mekanisme fallback untuk menjaga kualitas respons sistem.

Tabel 7. Rekap Hasil Pengujian Sistem Nova AI

Hasil Pengujian	Jumlah Skenario	Persentase
Sesuai Ekspektasi (Benar)	25	83,33%
Tidak Sesuai Ekspektasi (Salah)	5	16,67%
Total	30	100%

Dari 30 skenario pengujian, 25 pertanyaan (83,33%) dijawab dengan tepat oleh sistem Nova AI, sedangkan 5 pertanyaan (16,67%) tidak sesuai ekspektasi. Ketidaksiuaian tersebut umumnya disebabkan oleh variasi bahasa atau ejaan yang belum terwakili dalam dataset pelatihan, serta pertanyaan yang memiliki ambiguitas semantik antar kategori intent yang berkaitan. Tingkat keberhasilan 83,33% ini cukup memadai untuk tahap implementasi awal chatbot informasi akademik dan dapat ditingkatkan lebih lanjut melalui perluasan dataset dan pengayaan knowledge base sebagaimana disarankan oleh Smutny & Schreiberova (2020).

KESIMPULAN

Berdasarkan hasil penelitian dan pembahasan, dapat disimpulkan bahwa model CNN berbasis Word Embedding Word2Vec berhasil diimplementasikan pada sistem chatbot Nova AI untuk mengklasifikasikan enam kategori intent pertanyaan mahasiswa FIKTI UMSU, yaitu dekan, dosen, fakultas, kaprodi, sapaan, dan UKT, dengan akurasi keseluruhan mencapai 99,19% pada data uji (123 dari 124 sampel terklasifikasi benar), di mana satu kesalahan klasifikasi terjadi pada intent kaprodi yang teridentifikasi sebagai dekan. Integrasi model CNN dengan knowledge base terstruktur memungkinkan chatbot memberikan respons yang tepat, relevan, dan informatif sesuai intent yang diklasifikasikan, sementara pengujian sistem menunjukkan tingkat keberhasilan 83,33% (25 dari 30 skenario), sehingga membuktikan kelayakan Nova AI sebagai asisten informasi akademik berbasis chatbot untuk mahasiswa FIKTI UMSU.

Untuk penelitian lanjutan, disarankan memperluas dan mendiversifikasi dataset pertanyaan agar meningkatkan kemampuan generalisasi model, memperkaya serta memutakhirkan knowledge base agar mencakup lebih banyak topik akademik, menerapkan skenario pengujian yang lebih beragam termasuk uji coba dengan pengguna nyata, serta mengeksplorasi model NLP yang lebih canggih seperti BERT atau arsitektur transformer lainnya yang berpotensi memberikan performa lebih tinggi pada teks pendek berbahasa Indonesia.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara atas dukungan dan fasilitas yang diberikan selama pelaksanaan penelitian ini.

DAFTAR PUSTAKA

- Adamopoulou, E., & Moussiades, L. (2020). Chatbots: History, technology, and applications. *Machine Learning with Applications*, 2, 100006. <https://doi.org/10.1016/j.mlwa.2020.100006>
- Chaves, A. P., & Gerosa, M. A. (2021). How should my chatbot interact? A survey on social characteristics in human–chatbot interaction design. *International Journal of Human–Computer Interaction*, 37(8), 729–758. <https://doi.org/10.1080/10447318.2020.1841438>
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *Proceedings of NAACL-HLT 2019*, 4171–4186. <https://doi.org/10.18653/v1/N19-1423>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Hadikosyah, A. A., & Hasibuan, W. R. (2026). Analisis sentimen publik terhadap kenaikan UKT pada Platform X menggunakan Support Vector Machine. *Indonesian Journal of Multidisciplinary Scientific Studies*, 4(6), 380–388. <https://doi.org/10.33151/ijomss.v4i6.1124>
- Huang, M., Zhu, X., & Gao, J. (2020). Challenges in building intelligent open-domain dialog systems. *ACM Transactions on Information Systems*, 38(3), 1–32. <https://doi.org/10.1145/3383123>
- Jurafsky, D., & Martin, J. H. (2020). *Speech and language processing* (3rd ed. draft). Stanford University. <https://web.stanford.edu/~jurafsky/slp3/>
- Kim, Y. (2014). Convolutional neural networks for sentence classification. *Proceedings of EMNLP 2014*, 1746–1751. <https://doi.org/10.3115/v1/D14-1181>
- Kowsari, K., Meimandi, K. J., Heidarysafa, M., Mendu, S., Barnes, L., & Brown, D. (2019). Text classification algorithms: A survey. *Information*, 10(4), 150. <https://doi.org/10.3390/info10040150>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*. <http://arxiv.org/abs/1301.3781>
- Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., & Gao, J. (2022). Deep learning–based text classification: A comprehensive review. *ACM Computing Surveys*, 54(3), 1–40. <https://doi.org/10.1145/3439726>
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63.

- Smutny, P., & Schreiberova, P. (2020). Chatbots for learning: A review of educational chatbots for the Facebook Messenger. *Computers & Education*, 151, 103862. <https://doi.org/10.1016/j.compedu.2020.103862>
- Tan, L., Yi, J., & Yang, F. (2024). Improving performance of massive text real-time classification for document confidentiality management. *Applied Sciences*, 14(4), 1565. <https://doi.org/10.3390/app14041565>
- Wang, H., & Li, X. (2022). Chinese news text classification based on convolutional neural network. *Journal on Big Data*, 4(1), 41–60. <https://doi.org/10.32604/jbd.2022.027717>
- Wang, H., Tian, K., Wu, Z., & Wang, L. (2020). A short text classification method based on convolutional neural network and semantic extension. *International Journal of Computational Intelligence Systems*, 14(1), 367. <https://doi.org/10.2991/ijcis.d.201207.001>
- Yan, D., Li, K., Gu, S., & Yang, L. (2020). Network-based bag-of-words model for text classification. *IEEE Access*, 8, 82641–82652. <https://doi.org/10.1109/ACCESS.2020.2991074>
- Yogatama, D., Dyer, C., Ling, W., & Blunsom, P. (2017). Generative and discriminative text classification with recurrent neural networks. *arXiv preprint arXiv:1703.01898*. <http://arxiv.org/abs/1703.01898>
- Young, T., Hazarika, D., Poria, S., & Cambria, E. (2018). Recent trends in deep learning based natural language processing. *IEEE Computational Intelligence Magazine*, 13(3), 55–75. <https://doi.org/10.1109/MCI.2018.2840738>
- Zhang, X., & LeCun, Y. (2016). Text understanding from scratch. *Advances in Neural Information Processing Systems*. <http://arxiv.org/abs/1502.01710>