

LSTM Ağları ile Kinaye Hedef Tespiti

Sarcasm Target Identification with LSTM Networks

Necva Bölücü, Burcu Can
Bilgisayar Mühendisliği Bölümü, HUNLP Araştırma Lab.
Hacettepe Üniversitesi, Ankara, Türkiye
{necva, burcucan}@cs.hacettepe.edu.tr

Özetçe —Geçmiş yıllarda, kinayeli metinler üzerine yapılan çalışmalarda temel hedef metinlerin kinaye içerip içermediğinin tespit edilmesiydi. Sosyal medya kullanımı ile birlikte siber zorbalığın yaygınlaşması, metinlerin sadece kinaye içerip içermediğinin tespit edilmesinin yanısıra kinayeli metindeki hedefin belirlenmesini de gerekli kılmaya başlamıştır. Bu çalışmada, kinayeli metinlerde hedef tespiti için bir derin öğrenme modeli kullanılarak hedef tespiti yapılmış ve elde edilen sonuçlar literatürdeki İngilizce üzerine olan benzer çalışmalarla kıyaslanmıştır. Sonuçlar, önerdiğimiz modelin kinaye hedef tespitinde benzer çalışmalara göre daha iyi çalıştığını göstermektedir.

Anahtar Kelimeler—kinaye hedef tespiti, tekrarlı sinir ağları, derin öğrenme.

Abstract—The earlier work on sarcastic texts mainly concentrated on detecting the sarcasm on a given text. With the spread of cyber-bullying with the use of social media, it becomes also essential to identify the target of the sarcasm besides detecting the sarcasm. In this study, we propose a deep learning model for target identification on sarcastic texts and compare it with other work on English. The results show that our model outperforms the related work on sarcasm target identification.

Keywords—sarcasm target identification, recurrent neural networks, deep learning.

I. GİRİŞ

Kinaye, ifadelerin ilk anlamı ile amaçlanan anlamı arasında çelişkiler yaratarak oluşturulan ifadelerdir. Örneğin ‘*Görüyorum ki; ciğer sağlığını çok umursuyorsun*’ cümlesi ile sigara içmenin sağlığa zararlı olduğu kinayeli bir biçimde ifade edilmektedir. Son yıllarda Facebook, Twitter gibi sosyal medya sitelerinin popülerliğinin artmasıyla birlikte, bu sitelerde kullanıcılar tarafından yapılan yorum sayıları çığ gibi artmıştır. Kullanıcılar, yorumlarında duygularını kinayeli cümlelerle ifade etme eğilimindedirler. Kullanıcı, aslında olmayan bir şeyi söylemek için kinayeli ifadeleri kullanır. Bu ifadelerin amacı da genellikle karşıdakini küçük düşürmektir.

Doğal dil işlemede, sosyal medyadaki kullanıcı yorumlarının artması ile kinayeli ifadelerin tespit edilmesi önemli bir problem olmuştur. Bu alanda yapılan çalışmalar büyük oranda duygu analizi ile sadece metinlerin kinaye içerip içermediğinin tespit edilmesini içermektedir [1]–[4]. Fakat, metnin kinayeli ifade içerip içermemesinin yanı sıra, ifadedeki hedefin belirlenmesi de önemli bir problemdir. Sosyal medya kullanımının artması ile birlikte siber zorbalığa maruz kalan insan sayısı da artmaktadır. Kinayeli ifadelerdeki hedefin tespit edilmesi, bu konuda önlem alınmasını da kolaylaştıracaktır.

Kinayeli metinlerde hedef tespiti için yapılan çalışmalar kısıtlıdır [5]–[7]. Günümüzde derin öğrenme yöntemlerinin yaygınlaşması ile görüntü işleme, doğal dil işleme gibi alanlarda, bu yöntemler birçok problem için kullanılmaya başlamıştır. Kinayeli metinlerde hedef tespiti problemi için de derin öğrenme yöntemleri kullanılarak çalışmalar gerçekleştirilmiştir [6]. Bu çalışmada derin öğrenme kullanarak kinayeli metinlerde hedef tespitinin yapılması hedeflenmektedir. Bu bildiride sunduğumuz model dile bağlı hiçbir özellik kullanmadan sadece sözcük vektörleri ile kinayeli metinlerde hedef tespitini gerçekleştirmektedir.

Çalışmanın geri kalanı şu şekilde düzenlenmiştir: Bölüm II, problem ile ilgili yapılan son çalışmaları özetlemektedir. Bölüm III, çalışmada kullanılan modeli açıklamaktadır. Bölüm IV, çalışmada kullanılan veri kümesini, değerlendirme metrikleri ve kullanılan parametrelerle birlikte sonuçları sunmaktadır. Bölüm IV-E ise, çalışma çıktılarını inceleyerek hata analizini sunmaktadır. Son olarak Bölüm V çalışmanın sonuçlarıyla birlikte gelecek çalışmalar için öneriler sunmaktadır.

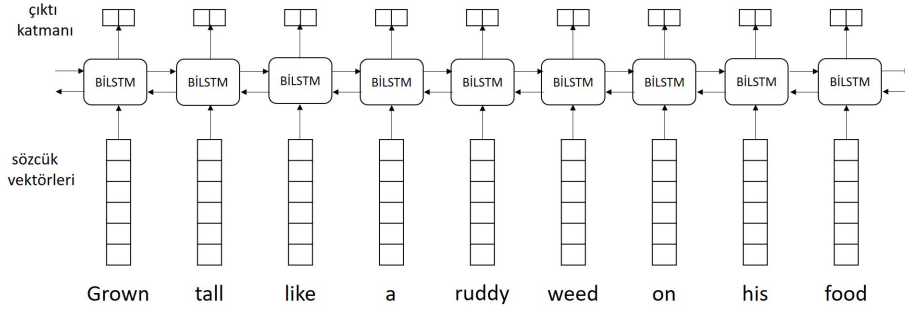
II. İLGİLİ ÇALIŞMALAR

Doğal dil işleme alanında kinaye ile ilgili çalışmalar metinlerin kinayeli ifade içerip içermediği üzerinde yoğunlaşmıştır [4]. Kinayeli metinlerde hedef tespiti problemi için literatürdeki çalışmalar son birkaç yılda yapılmış olup çok kısıtlıdır.

Joshi ve arkadaşları [5] literatürde bu alandaki ilk çalışmayı gerçekleştirenin yanısıra bu problem için bir veri kümesi de oluşturmuşlardır. Çalışmalarında 3 farklı model sunmuşlardır: a) Metindeki hedefleri belirlemek için 9 farklı kuraldan oluşan kural tabanlı bir model, b) Sözcük etiketleme algoritmaları ile eğitilmiş hedeflerin etiketli olduğu bir veri kümesi üzerinden öğrenen bir model ve c) hedefleri belirlemede iki modelin çıktılarını kullanan bir karma (hybrid) model.

Patro ve arkadaşları [6] bu problem için derin öğrenme tabanlı bir model sunmuşlardır. Çalışmalarında çift yönlü LSTM modeli ile birlikte toplumsal dilbilimsel özellikler kullanmışlardır.

Bu probleme ilgiyi arttırmak için, 2019 yılında Australasian Language Technology Association (ALTA) [8] tarafından bir yarışma (shared task) ve yeni bir veri kümesi yayınlanmıştır. Parameswaran ve arkadaşları [7] bu yarışma kapsamında yayınlanan çalışmalarında sınıflandırıcı toplulukları (ensemble of classifiers) ve bir kural tabanlı model önermiş ve bu modeli [8] yarışma kapsamında yayınlanan veri kümesi üzerinde denemişlerdir.



Şekil 1: Çift yönlü LSTM tabanlı kinaye hedefi tespit modeli

Kinayeli ifadeler için diğer çalışmalar, metinlerin kinayeli ifade içerip içermediğine yoğunlaşmaktadır. Bu problem son dönemde üzerine fazlaca çalışılan konulardan olmuştur [1]. Literatürde kinayeli metinler üzerinde derin öğrenme modeli kullanılarak yapılan çalışmalardan bir tanesi de Poria ve arkadaşlarının [1] çalışmasıdır. Poria ve arkadaşları [1] Konvolüsyonel Nöral Ağ (Convolutional Neural Network - CNN) kullanarak çıkardıkları özellikleri SVM modeli ile sınıflandırmaktadır. Bu çalışmanın diğer çalışmalardan farkı, özellik çıkarımı işleminin otomatik yapılması ve diğer çalışmalara göre daha küçük bir özellik kümesi ile çalışabilmesidir.

Son olarak, metinlerin kinayeli ifade içerip içermemesi problemi için, Joshi ve arkadaşları [4] literatürde yapılan çalışmaları, kullanılan veri kümelerini ve kullanılan özellikleri özetleyen bir çalışma sunmaktadır.

III. YÖNTEM

Bu bölümde, bu çalışma kapsamında oluşturduğumuz iki farklı model açıklanmaktadır. İlk model, Çift Yönlü Uzun Kısa Dönemli Bellek Ağları (Bi-Directional Long Short Term Memory Network - BiLSTM) [9] kullanmakta, ikinci önerdiğimiz model ise BiLSTM ile Koşullu Rasgele Alan (Conditional Random Field - CRF) kullanmaktadır.

A. Çift Yönlü LSTM Modeli

Çift yönlü LSTM modeli ile hedef sözcüklerin seçilebilmesi için BiLSTM modeli ile bağlama bağımlı olarak kinaye hedefi içerebilecek sözcüklerin belirlenmesi hedeflenmektedir. Bu şekilde gelecek (forward states) ve geçmiş özellikleri (backward states) kullanarak daha doğru bir tespit yapılması da mümkün olabilmektedir.

Model için kullanılan eğitim kümesi $s = (x_1, x_2, \dots, x_n)$ olarak verilen ve x ile ifade edilen cümlelerden meydana gelmektedir. Bu eğitim kümesindeki her cümle için, o cümledeki sözcüklerden herhangi biri hedef olarak belirlenmiş ise 1, değilse 0 olarak etiketlenmiştir.

Oluşturduğumuz LSTM modeli D eğitim kümesindeki cümleleri girdi olarak almaktadır. Verilen s cümlesi için modelin çıktısı $y = (y_1, y_2, \dots, y_n)$ olacak şekilde her sözcük için hedef olup olmadığını üretmektedir. Bu durumda, $y_i = 0$, i . sözcüğün hedefi belirleyen sözcük olmadığını, $y_i = 1$ ise i . sözcüğün hedefi belirleyen sözcük olduğunu ifade etmektedir. Modelin mimarisi Şekil 1'de verilmektedir.

Test aşamasında girdi olarak verilen cümle için elde edilen çıktıda 1 etiketine sahip olan sözcükler arasında sözcük türü kişi ve iyelik zamiri olan sözcükler hedef listesine eklenmektedir. Eğer hiçbir sözcük için 1 etiketi üretilmediyse ya da 1 etiketi üretilen sözcükler arasında kişi ve iyelik zamiri olan sözcükler yok ise, o cümle için hedef "OUTSIDE" olarak etiketlenmektedir. Yani o cümlede herhangi bir kinaye hedefi olmadığı anlamına gelmektedir.

B. Çift Yönlü LSTM-CRF Modeli

İkinci önerilen model, BiLSTM ve CRF katmanlarından oluşmaktadır. Modelde BiLSTM ara temsil gösterimi üretmek için kullanılmaktadır. Sonrasında, bu ara temsil değerleri CRF katmanına girdi olarak verilmektedir. CRF katmanının çıktıları hedef tespiti için kullanılmaktadır. CRF her sözcük için en uygun etiketin (hedef - hedef olmaması) tahmin edilmesine izin vermekte ve etiket düzeyinde bağımlılık ilişkilerini (dependency) yakalamaktadır. Modelin mimarisi Şekil 2'de verilmektedir.

Test aşamasında etiketleme işlemi, LSTM modelinin test aşaması ile aynı şekilde yapılmıştır.

IV. DENEYLER VE SONUÇLAR

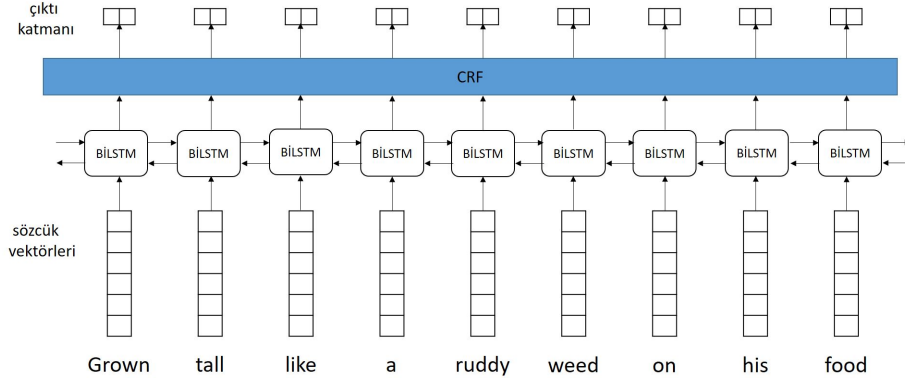
Kinayeli metinlerdeki hedef tespiti için önerilen modelin performansını ölçmek için farklı hiperparametreler ile deneyler gerçekleştirilmiştir. Bu bölümde, kullanılan veri kümesi, değerlendirme metrikleri ve en iyi sonucun elde edildiği hiperparametreler ile birlikte deney sonuçları verilmektedir.

A. Veri kümesi

Bu çalışmada, Joshi ve arkadaşlarının [5] kinaye hedef tespit problemi için özel olarak oluşturdukları Book Snippet adlı veri kümesi kullanılmıştır. Book Snippet [5] veri kümesi, kinayeli ifade içeren 224 kitap pasajından oluşmaktadır. Pasajlarda eğer kinaye hedefi bulunmuyorsa, cümle "OUTSIDE" olarak etiketlenmiştir. Veri kümesini daha iyi anlayabilmek için kinayeli cümleler ve onlara karşılık gelen hedeflere örnekler Tablo I'da verilmektedir.

B. Değerlendirme Metrikleri

Deneyler iki değerlendirme metriği ile değerlendirilmiştir: Kesin Eşleme Doğruluğu (Exact Match Accuracy) ve Zar Skoru (Dice Score). Bu metrikler, bilgi çıkarımında (information extraction) yaygın olarak değerlendirme amaçlı kullanılmaktadır [10].



Şekil 2: Çift yönlü LSTM-CRF tabanlı kinaye hedefi tespit modelinin mimarisini

Tablo I: Book Snippet veri kümesinden [5] kinaye içeren örnek cümleler

Cümle	Hedef(ler)
Grown tall, like a ruddy weed, on his food.	his food
Oh, and I suppose the apples ate the cheese.	Outside
You really are a ray of sunshine, aren't you?	you You
Luchesi cannot tell amontillado from a sherry	Luchesi
The more this guy talked, the more he sounded like a fortune cookie.	this guy he

- **Kesin Eşleme Doğruluğu (Exact Match (EM) Accuracy):** Cümlede tahmin edilen hedeflerin listesi ile gerçek hedeflerin listesi birebir eşleşme gösteriyorsa kesin eşleme oluşur. Kesin eşleme doğruluğu aşağıdaki formülde verildiği gibi hesaplanmaktadır:

$$A = \frac{C_s}{C_w} \quad (1)$$

C_s kesin eşleme görülen cümlelerin sayısını, C_w ise veri kümesindeki toplam cümle sayısını göstermektedir.

- **Zar skoru (Dice Score (DC)):** Zar skoru [11] iki örneklem üzerindeki benzerliği hesaplamak için kullanılmaktadır. Kinaye hedefi tespit problemi için tam eşleme doğruluğu metriğinden daha iyi bir metrik olduğu kabul edilir, çünkü tahmin edilen hedeflerde eksik veya fazladan sözcükler bulunabilir. Zar skoru metriği aşağıda verildiği gibi hesaplanmaktadır:

$$DC = \frac{2 * (X \cap Y)}{X + Y} \quad (2)$$

X ve Y sırasıyla tahmin edilen ve gerçek hedef listesidir.

C. Hiperparametreler

Bu modelin eğitiminde ve testinde Book Snippet [5] veri kümesi kullanılmıştır. Bu veri kümesinin küçük olmasından dolayı k katlamalı çapraz doğrulama (k -fold cross validation) yöntemi farklı $k \in \{3, 4, 5, 7, 10\}$ parametreleri ile test edilmiştir.

Modelin girdi katmanında sözcük vektörleri kullanılmaktadır. Her cümlede sözcükler onlara karşılık gelen sözcük vektörlerine çevrilerek girdi katmanını beslemektedir. Sözcük vektör-

leri olarak Standford Üniversitesi'nin yayımladığı Glove [12] vektörleri kullanılmaktadır. Farklı boyuttaki (50, 100, 300) vektörler denenmiş ve en iyi skor 50 boyutlu vektörler ile elde edilmiştir.

Önerilen modeller için hiperparametreler veri kümesindeki örnek azlığından dolayı eğitim kümesi üzerinde denenmiştir. BILSTM ve BILSTM-CRF modelleri için en iyi sonuçları elde ettiğimiz hiperparametreler Tablo III'de verilmiştir.

D. Sonuçlar

Yöntem bölümünde anlatılan modelin başarısını ölçmek için zar skoru [11] ve tam eşleme metrikleri kullanılmıştır. Deneysel sonuçlar, bu problem için literatürde bu veri kümesi üzerinde gerçekleştirilen çalışmalar ([5], [6]) ile kıyaslanmıştır. Literatürdeki çalışmaların sonuçları deney sonuçları ile birlikte Tablo IV'te gösterilmektedir.

Modelin sonuçları, literatürdeki Joshia ve arkadaşlarının [5], ve Patro ile arkadaşlarının [6] sonuçları ile kıyaslandığında önerilen modelin bu problemin çözümünde çok daha iyi sonuç verdiğini göstermektedir. Önerilen çift yönlü LSTM modeli, Patro ve arkadaşlarının [6] önerdiği modelden farklı olarak girdi katmanında sadece sözcük vektörlerini kullanmıştır ve test aşamasında sadece kişi ve iyelik zamiri sözcük türüne sahip sözcükleri hedef sözcük olarak seçmiştir. Özellikle kesin eşleme doğruluğuna ait sonuçlar göz önünde bulundurulduğunda, modelin tahmin edilen hedefleri çok yüksek oranda doğru bulduğu görülmektedir. Bu başarının bir sebebi de hedef sözcüklerin seçiminde sözcük türünün de önemli bir bilgi taşımasıdır.

E. Hata Analizi

BILSTM-CRF modeli ile elde edilen doğru tahminler Tablo V'te ve yanlış çıktılara örnekler ise Tablo II'de verilmektedir. Örneklerde verilen cümleler her türlü hatayı açıkça göstermek için seçilmiştir. 1. cümlede gerçek hedef listesindeki tüm sözcükler tahmin edilebilmesine rağmen bazı sözcükler tahmin edilememiştir. 2. cümlede gerçek hedef sözcükleri önerdiğimiz model ile bulabilmemize rağmen fazladan bazı sözcükler de hedef olarak seçilmiştir. 3. örnekte gerçek hedef ile tamamen alakasız sözcükler hedef sözcük olarak seçilmiştir. Son örnekte ise model hiçbir sözcüğü doğru tahmin edememiş ve cümleyi "OUTSIDE" olarak etiketlemiştir.

Tablo II: BILSTM-CRF modeli ile elde edilen hatalı çıktılar

Cümle	Tahmin edilen hedef	Gerçek hedef
A woman's weapon is her tongue.	her	woman's her
... my knife out of his side and looked at it. "Nice knife." The voice was deep but female. I threw my ...	my I my my	my I
There's nothing like a headless corpse to bring a touch of excitement into one's life.	life	headless corpse
Grown tall, like a ruddy weed, on his food.	Outside	his food

Tablo III: En iyi sonuç veren modellere göre belirlenen parametreler

	BILSTM	BILSTM-CRF
Sözcük vektörleri	GloVe [12] 6B 50d	GloVe [12] 6B 50d
LSTM katman sayısı	1	1
İyileştirici (Optimizer)	Adam [13]	Adam [13]
Seyreltme parametresi (Dropout)	0.3	0.2
Saklı sayısı (Hidden size)	32	32
Dönem (Epoch)	30	40
k parametresi	10	10

Tablo IV: Önerilen modellerin diğer modellerle kıyaslı sonuçları

Model	EM	DC
BILSTM	80.80	85.53
BILSTM-CRF	87.50	92.28
Hybrid OR [5]	7.01	32.68
Hybrid AND [5]	16.51	21.28
LSTM [6]	23.37	87.57
BILSTM [6]	30.14	87.66
TD-LSTM [6]	25.97	87.71
BILSTM + sif [6]	31.17	88.16

Veri kümesinde en sık kullanılan hedef sözcükler: "OUTSIDE" ve zamirlerdir (kişi, işaret ve iyelik zamirleri - this, your, he, her, you). Tahmin edilen hedef sözcükler incelendiğinde en çok hata "OUTSIDE" etiketinin tahmin edilmesinde görülmüştür. Bu da veri kümesinde etiketlerin dengeli olarak dağılmamasından kaynaklanmaktadır. Model çıktıları incelendiğinde büyük çoğunlukla model gerçek hedef listesindeki sözcükleri büyük oranda tahmin edebilmekte, kinaye hedefiyle ilgili olmayan sözcükler genelde seçilmemektedir.

V. SONUÇ VE GELECEK ÇALIŞMALAR

Bu çalışmada, yeni bir problem olan kinayeli metinlerde hedef belirleme problemi üzerine iki farklı model önermekteyiz. Bu problemde temel amaç kinayeli metinlerde hedef tespitini yapabilmektir. Kinayeli ifadelerde genellikle kinayenin yöneltildiği bir hedef (genellikle bir özne) olmaktadır. Şimdiye kadar yapılan çalışmalar, daha çok metinlerdeki kinayeli ifadelerin tespitine yönelik olup, kinayenin hedefini bulmaya yönelik oldukça az çalışma bulunmaktadır.

Bu problem için BILSTM ve BILSTM-CRF tabanlı derin öğrenme modelleri önerilmiş ve bu modeller ile elde edilen sonuçlar önceki çalışmalarla kıyaslanmıştır. Çalışmada önerilen BILSTM-CRF modeli ile en yüksek zar skoru olarak 92.28 ve en yüksek kesin eşleşme doğruluğu olarak 87.50 elde edilmiştir. Elde edilen sonuçlar, bu problem için kural tabanlı makine öğrenmesi modelinin yerine derin öğrenme modelinin daha başarılı olabileceğini göstermektedir.

Gelecek çalışmalar için amacımız, bu problem için sözcüklerin semantik özelliklerini de modele dahil etmektir.

Tablo V: BILSTM-CRF modeli ile elde edilen doğru çıktılar

Cümle	Tahmin edilen hedef	Gerçek hedef
I cannot speak well enough ...	Outside	Outside
Discord says it's a good idea. ...	Discord	Discord
Niko was a man of few words and ...	Niko	Niko
We don't have dealings. He ...	He	He

KAYNAKLAR

- [1] S. Poria, E. Cambria, D. Hazarika, and P. Viji, "A deeper look into sarcastic tweets using deep Convolutional Neural Networks," *arXiv preprint arXiv:1610.08815*, 2016.
- [2] D. Bamman and N. A. Smith, "Contextualized sarcasm detection on Twitter," in *Ninth International AAAI Conference on Web and Social Media*, 2015.
- [3] M. Bouazizi and T. O. Ohtsuki, "A pattern-based approach for sarcasm detection on Twitter," *IEEE Access*, vol. 4, pp. 5477–5488, 2016.
- [4] A. Joshi, P. Bhattacharyya, and M. J. Carman, "Automatic sarcasm detection: A survey," *ACM Computing Surveys (CSUR)*, vol. 50, no. 5, p. 73, 2017.
- [5] A. Joshi, P. Goel, P. Bhattacharyya, and M. Carman, "Sarcasm target identification: Dataset and an introductory approach," in *Proceedings of the Eleventh International Conference on Language Resources and Evaluation (LREC 2018)*, 2018.
- [6] J. Patro, S. Bansal, and A. Mukherjee, "A deep-learning framework to detect sarcasm targets," in *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, 2019, pp. 6337–6343.
- [7] P. Parameswaran, A. Trotman, V. Liesaputra, and D. Eysers, "Detecting target of sarcasm using ensemble methods," *ALTA 2019*, p. 197.
- [8] D. Mollá and A. Joshi, "Overview of the 2019 ALTA shared task: Sarcasm target identification," *ALTA 2019*, p. 192.
- [9] M. Schuster and K. K. Paliwal, "Bidirectional Recurrent Neural Networks," *IEEE Transactions on Signal Processing*, vol. 45, no. 11, pp. 2673–2681, 1997.
- [10] M. Michelson and C. A. Knoblock, "Unsupervised information extraction from unstructured, ungrammatical data sources on the World Wide Web," *International Journal of Document Analysis and Recognition (IJ DAR)*, vol. 10, no. 3-4, pp. 211–226, 2007.
- [11] T. A. Sorensen, "A method of establishing groups of equal amplitude in plant sociology based on similarity of species content and its application to analyses of the vegetation on Danish commons," *Biologiske Skrifter*, vol. 5, pp. 1–34, 1948.
- [12] J. Pennington, R. Socher, and C. Manning, "Glove: Global vectors for word representation," in *Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)*, 2014, pp. 1532–1543.
- [13] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.