



Türkçe Metin Madenciliği için Çalışan Bellek Bağlantıları Tabanlı Uzun Kısa Süreli Bellek Mimarisi

Aytuğ Onan^{1*}

¹ İzmir Kâtip Çelebi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, İzmir, Türkiye (ORCID: 0000-0002-9434-5880)

(2nd International Conference on Applied Engineering and Natural Sciences ICAENS 2022, March 10-13, 2022)

(DOI: 10.31590/ejosat.1080239)

ATIF/REFERENCE: Onan, A. (2022). Türkçe metin madenciliği için çalışan bellek bağlantıları tabanlı uzun kısa süreli bellek mimarisi. *European Journal of Science and Technology*, (34), 239-246.

Öz

Metin sınıflandırma, metin belgelerinin önceden belirlenmiş sınıf etiketlerinden birine atanmasına yönelik bir doğal dil işleme alanıdır. Metin sınıflandırma, aralarında duygu analizi, konu etiketleme, soru yanıtlama ve diyalog eylemi sınıflandırmanın da yer aldığı birçok doğal dil işleme problemine kullanılmaktadır. Metin sınıflandırma, haber metinlerinin filtrelenmesi ve organizasyonu, istenmeyen e-posta içeriklerinin filtrelenmesi gibi birçok uygulama alanına sahiptir. Son yıllarda, metin sınıflandırma alanında, derin sinir ağı tabanlı mimariler ve sinirsel dil modelleri sıklıkla kullanılmaktadır. Uzun kısa süreli bellek tabanlı mimariler (LSTM), uzun süreli bağımlılıkları öğrenirken, geleneksel tekrarlayan sinir ağlarında gözlemlenen patlayan ve kaybolan gradyanları azaltmak için geçit mekanizmasını kullanır. Bu nedenle, LSTM ve türevi mimariler, birçok dizi modelleme görevinde yaygın kullanıma sahiptir. LSTM tabanlı mimarilerde, bellek hücresi temel bilgileri içermesine karşın, geçit mekanizmasını doğrudan etkilemesine izin verilmez. Bu çalışmada, Türkçe duygu analizi için, tekrarlayan sinir ağı, uzun kısa süreli bellek, geçitli tekrarlayan birim, gözetleme deliği tabanlı uzun kısa süreli bellek mimarisi ve çalışan bellek bağlantıları tabanlı uzun kısa süreli bellek mimarisinin başarımlarını karşılaştırmalı olarak değerlendirilmektedir. Derlemin temsilinde, word2vec, fastText ve GloVe kelime gömme yöntemleri değerlendirilmiştir. Deneysel analizler, çalışan bellek bağlantıları tabanlı uzun kısa süreli bellek mimarisinin Türkçe metin belgeleri üzerinde duygu analizi için, gözetleme deliği tabanlı uzun kısa süreli bellek mimarisi, uzun kısa süreli bellek ve geçitli tekrarlayan birim mimarisine kıyasla daha yüksek doğru sınıflandırma oranı elde ettiğini göstermektedir.

Anahtar Kelimeler: Uzun kısa süreli bellek, Metin madenciliği, Derin öğrenme, Makine öğrenmesi, Çalışan bellek bağlantıları.

Long Short Term Memory Based on Working Memory Connections for Turkish Text Mining

Abstract

Text classification is a natural language processing area for assigning text documents to one of the predetermined class labels. Text classification is used in many natural language processing problems, including sentiment analysis, topic tagging, question answering, and dialogue action classification. It has many applications, such as text classification, filtering and organization of news texts, and filtering of spam e-mail contents. In recent years, deep neural network-based architectures and neural language models have been used frequently in the field of text classification. Long-term memory-based architectures (LSTM) use gate mechanisms to reduce the vanishing and exploding gradients observed in the conventional recurrent neural networks when learning long-term dependencies. Therefore, LSTM and LSTM-based architectures have widespread use in many sequence modeling tasks. In LSTM-based architectures, although the memory cell contains the basic information, it is not allowed to directly affect the gate mechanism. In this study, the performance of recurrent neural network, long short-term memory, gated recurrent unit, peephole-based long-short-term memory architecture and working-memory connections-based long-term memory architecture are comparatively evaluated for Turkish sentiment analysis. In the representation of the corpus, word2vec, fastText and GloVe word embedding methods were evaluated. Experimental analyzes show that working memory connections-based long short-term memory architecture achieves higher classification accuracy for sentiment analysis on Turkish text documents compared to peephole-based long short-term memory architecture, long short-term memory and gated recurrent unit architecture.

Keywords: Long short-term memory, Text mining, Deep learning, Machine learning, Working memory connections.

* Sorumlu Yazar: İzmir Kâtip Çelebi Üniversitesi, Mühendislik-Mimarlık Fakültesi Fakültesi, Bilgisayar Mühendisliği Bölümü, İzmir, Türkiye, ORCID: 0000-0002-9434-5880, aytug.onan@ikcu.edu.tr

1. Giriş

Metin sınıflandırma, metin belgelerinin önceden belirlenmiş sınıf etiketlerine atanmasına yönelik bir doğal dil işleme (DDİ) alanıdır. Metin sınıflandırma, DDİ alanındaki duygu analizi, konu etiketleme, soru yanıtlama ve diyalog eylemi sınıflandırma gibi birçok görev için kritik öneme sahiptir [1]. Metin sınıflandırma yöntemleri, aralarında haber metinlerinin filtrelenmesi ve organizasyonu, belge organizasyonu, belge geri getirmesi ve istenmeyen e-postaların filtrelenmesi gibi birçok farklı alanda başarıyla uygulanmaktadır [2]. Duygu analizi, metin belgelerinde yer alan belirli bir konu ya da nesneye ilişkin duygu, his, algı gibi değerlendirmeleri belirlemeye yönelik bir metin madenciliği çalışma alanıdır. Yapısal olmayan metin belgeleri üzerinde gerçekleştirilen uygulamalar, bireysel karar vericiler, iş organizasyonları ve hükümetler için oldukça kullanışlıdır [3, 4]. Böylelikle, düzenlemelere, ürünlere, servislere ya da organizasyonlara ilişkin kamusal görüş ve geri bildirimler kolaylıkla çıkarılabilmektedir. Duygu analizi yöntemleri, temelde makine öğrenmesi tabanlı ve sözlük tabanlı yaklaşımlar olmak üzere iki temel sınıf altından incelenmektedir [5]. Sözlük tabanlı yaklaşımlarda, duygu analizi, belgedeki sözcüklerin ya da tümcelerın anlamsal yöneliminden yola çıkılarak hesaplanır. Makine öğrenmesi tabanlı yaklaşımlarda ise, metin belgeleri, sözcük torbası yöntemi başta olmak üzere uygun bir temsil yöntemi ile temsil edildikten sonra, Naive Bayes, destek vektör makinesi, k-en yakın komşu ve yapay sinir ağları gibi sınıflandırma algoritmaları ile öğrenme modeli oluşturulması söz konusudur [6]. Makine öğrenmesi yöntemlerinde yaygın kullanıma sahip metin temsil yöntemi olan sözcük torbası yöntemi, metin sözdizimi, kelime sıralaması ve dilbilgisi kurallarını göz ardı etmektedir. Ayrıca, bu temsil yönteminde yüksek boyutluluk ve veri seyrekliği gibi problemler gözlenmektedir. Buna ek olarak, özenlilik mühendisliği zaman alıcı ve emek yoğun bir iştir [7].

Önceden bahsedilen geleneksel sınıflandırma yöntemlerinin dezavantajlarını ortadan kaldırmak amacıyla, DDİ alanındaki son çalışmalarda, kelime gömme yöntemleri ve derin sinir ağı mimarileri kullanılmaktadır. Kelime gömme yöntemleri, metin belgelerinin sabit uzunluklu vektörler aracılığıyla yoğun bir biçimde temsil edildiği bir yapı sunar. Kelime gömme tabanlı metin temsili, daha düşük boyutlulukla, daha yoğun metin temsili olan hale getirerek, sözcük torbası modellerinde görülen seyreklik ve yüksek boyutluluk sorunlarını ortadan kaldırır [8]. Word2vec, fastText ve GloVe gibi kelime gömme yöntemleri, yakın zamanda, duygu analizi ve konu çıkarma da dahil olmak üzere birçok DDİ görevinde yüksek başarımlar sağlamıştır [7, 8]. Evrişimli sinir ağları (CNN), tekrarlayan sinir ağları (RNN), uzun kısa süreli bellek mimarisi (LSTM) ve geçitli tekrarlayan birim (GRU) gibi derin öğrenme mimarileri, DDİ görevlerinde yüksek başarımla uygulanabilmektedir.

Uzun kısa süreli bellek tabanlı mimariler (LSTM), uzun süreli bağımlılıkları öğrenirken, geleneksel tekrarlayan sinir ağlarında gözlemlenen patlayan ve kaybolan gradyanları azaltmak için geçit mekanizmalarını kullanır. Bu nedenle, LSTM ve türevi mimariler, birçok dizi modelleme görevinde yaygın kullanıma sahiptir [9]. LSTM tabanlı mimarilerde, bellek hücresi temel bilgileri içermesine karşın, geçit mekanizmasını doğrudan etkilemesine izin verilmez. Bu çalışmada, Türkçe duygu analizi için, tekrarlayan sinir ağı, uzun kısa süreli bellek, geçitli tekrarlayan birim, gözetleme deliği tabanlı uzun kısa süreli

bellek mimarisi ve çalışan bellek bağlantıları tabanlı uzun kısa süreli bellek mimarisinin başarımlarını karşılaştırmalı olarak değerlendirilmektedir. Derlemin temsiliinde, word2vec, fastText ve GloVe kelime gömme yöntemleri değerlendirilmiştir. Deneysel analizler, çalışan bellek bağlantıları tabanlı uzun kısa süreli bellek mimarisinin Türkçe metin belgeleri üzerinde duygu analizi için, gözetleme deliği tabanlı uzun kısa süreli bellek mimarisi, uzun kısa süreli bellek ve geçitli tekrarlayan birim mimarisine kıyasla daha yüksek doğru sınıflandırma oranı elde ettiğini göstermektedir.

Çalışmanın geri kalanı şu şekilde yapılandırılmıştır. İkinci bölümde, ilgili çalışmalara değinilmektedir, üçüncü bölümde çalışmanın metodolojisini oluşturan kelime gömme yöntemlerine, derin öğrenme mimarilerine ve çalışan bellek bağlantısı mekanizmasına ilişkin ayrıntılar sunulmaktadır. Dördüncü bölümde, deneysel sonuçlar ve tartışma, son bölümde ise çalışmanın genel sonuçları sunulmaktadır.

2. İlgili Çalışmalar

Metin madenciliği ve duygu analizi alanındaki son yıllardaki çalışmalar, kelime gömme yöntemleri ve derin sinir ağı mimarileri kullanmaya odaklanmıştır. Uzun kısa süreli bellek (LSTM) tabanlı mimariler, uzun süreli bağımlılıkları modelleme yeteneklerinden dolayı duygu analizi de dahil olmak üzere DDİ görevlerinde yaygın olarak kullanılmaktadır [10]. Örneğin, Xu ve ark. [11], belleği değişen unutmaya oranlarıyla birçok sınıfa bölerek uzun metinlerdeki anlamsal bilgiyi yakalamak için önbelleğe alınmış LSTM tabanlı bir mimari sunmuş ve ağınlı anlamsal bilgiyi tekrarlayan bir birim içinde daha uzun süre tutmasını sağlamıştır. Başka bir çalışmada Rao ve ark. (2018), uzun metin belgelerinde tümceler arasındaki anlamsal bilgileri yakalamak için LSTM tabanlı bir mimari sunmuştur. Sunulan şemada, ilk katman, cümle vektörlerini altına yatan tümcelerın anlambilimiyle tanımlamak için konuşlandırılmış ve ikinci katman, tümcelerın ilişkilerini kodlamak için kullanılmıştır.

Benzer şekilde, Al-Smadi ve ark. [12], Arapça incelemelerin duygu analizi için anlamsal bilgileri modellemek amacıyla LSTM tabanlı bir mimari kullanmıştır. Başka bir çalışmada, Lu ve ark. [13], duygu analizi için, P-LSTM olarak adlandırılan, LSTM tabanlı bir mimari sunmuştur. P-LSTM'de tek kelime gömme kullanmak yerine, üç kelimelik cümle gömme kullanılmıştır. P-LSTM, ifade gömme katmanının özellik vektörlerini LSTM gizli katmanının özellik vektörü ile entegre eden ifade faktörü mekanizmasını tanıtır. Bu sayede metin belgelerinden daha kesin bilgiler alınabilir. Benzer şekilde, Ma ve ark. [14] çalışmalarında, Sentic-LSTM olarak adlandırılan, LSTM tabanlı bir mimari sunmuştur. Bu mimaride, derin sinirsel sıralı modelde sağduyu bilgisinden yararlanmaya özel bir vurgu yapılarak, hedeflenen en-boy tabanlı duygu analizi için bilgi açısından zenginleştirilmiş bir yaklaşım sunulmuştur. LSTM ve türevleri, umut verici tahmin performansı ile duygu analizinde yaygın olarak kullanılmıştır. Landi ve ark. [15] tarafından gerçekleştirilen çalışmada, çalışan bellek bağlantıları tabanlı uzun kısa süreli bellek mimarisi sunulmuştur. Çalışan bellek bağlantıları tabanlı LSTM mimarisinin, görüntü altyazılama, metin sınıflandırma gibi bazı temel DDİ görevlerinde başarılı sonuçlar elde ettiği gözlenmiştir.

3. Metodoloji

Bu bölümde, çalışmanın metodolojisini oluşturan kelime gömme yöntemleri, derin öğrenme mimarileri ve çalışan bellek bağlantısı mekanizmaları açıklanmaktadır.

3.1. Kelime Gömme Yöntemleri

Word2vec modeli, yapay sinir ağı tabanlı bir kelime gömme şeması olarak giriş katmanı, çıkış katmanı ve gizli katmandan oluşur [16]. Belirli bir kelimenin başka kelimelerde köklenme olasılığını belirleyerek kelimeleri gömmeyi öğrenmeye çalışır. Model, atlama gramı (SG) ve sürekli sözcük torbası (CBOW) olmak üzere iki temel mimariden oluşur. CBOW, her kelimenin içeriğini girdi olarak alarak hedef kelimeyi tanımlar; SG mimarisi ise nesnel sözcükleri girdi olarak kullanarak hedef sözcüğün etrafındaki sözcükleri tahmin eder [17]. Az miktarda veri ile CBOW mimarisi iyi çalışabilir. Büyük veri kümelerinde SG mimarisi etkin bir şekilde çalışır.

FastText modeli, metin belgelerine kelime yerleştirmenin başka bir etkili yoludur. Her kelimenin karakteri, bu düzende n grama bölünmüştür. Eğitim setindeki her n -gram için kelime vektörleri tasarlanmıştır. FastText modeli, morfolojik olarak zengin diller ve nadir kelimeler için daha iyi bir kelime entegrasyon şeması sağlar [18].

Küresel vektör şeması (GloVe), metin belgelerine kelime yerleştirmenin etkili bir şekilde öğrenilmesi için word2vec tabanlı bir temsildir [19]. Model bir global log-bilineer regresyon modelidir.

3.2. Derin Öğrenme Mimarileri

Evrişimli sinir ağları (CNN), verileri ızgara tabanlı bir topoloji kullanarak işleyen ve evrişim olarak bilinen özel bir matematiksel işlem biçimine sahip derin sinir ağı mimarileridir. CNN'ler çok katmanlıdır ve DDİ uygulamalarında yerel özellik çıkarımı için kullanılır. Bu ağlardaki evrişim işlemi, giriş özellikleri üzerindeki doğrusal filtreler aracılığıyla gerçekleşir [20].

Tekrarlayan sinir ağı (RNN), dizi modelleme için kullanılan bir tür derin sinir ağıdır [21]. RNN'de, nöronlar arasındaki bağlantılar yönlendirilmiş bir grafik oluşturur. RNN, giriş dizilerini kendi iç durumuna göre işleyebilir ve bu nedenle NLP

$$i_t = \sigma(W^{(i)}x_t + U^{(i)}h_{t-1} + b^{(i)}) \quad (1)$$

$$f_t = \sigma(W^{(f)}x_t + U^{(f)}h_{t-1} + b^{(f)}) \quad (2)$$

$$o_t = \sigma(W^{(o)}x_t + U^{(o)}h_{t-1} + b^{(o)}) \quad (3)$$

$$u_t = \tanh(W^{(u)}x_t + U^{(u)}h_{t-1} + b^{(u)}) \quad (4)$$

$$c_t = i_t \circ u_t + f_t \circ c_{t-1} \quad (5)$$

$$h_t = o_t \circ \tanh(c_t) \quad (6)$$

Burada x_t , LSTM birimine giriş vektörünü, f_t unutma kapısı için aktivasyon vektörünü, i_t giriş kapısı için aktivasyon vektörünü, o_t çıkış kapısı için aktivasyon vektörünü, h_t gizli durum vektörünü ve c_t ise hücre durum vektörü. Bu modelde W ağırlık matrislerine, b ise bias vektör parametrelerine karşılık gelmektedir.

görevleri için uygundur. Her bir RNN çıkışı, her bir örnek üzerinde aynı işlevi tekrar tekrar gerçekleştirerek hesaplanmaktadır.

Uzun kısa süreli bellek ağı (LSTM), aşırı artan veya aşırı azalan gradyan problemini ortadan kaldırmak için unutma kapılarının kullanıldığı RNN'lere dayanan derin bir sinir ağı mimarisidir. Geleneksel tekrarlayan sinir ağı mimarilerinden farklı olarak, LSTM, sınırlı sayıda zaman adımı boyunca hata geri yayılımına izin verir [22]. Tipik bir LSTM birimi, bir hücreden ve üç farklı kapı türünden oluşur: bir giriş kapısı, bir çıkış kapısı ve bir unutma kapısı. Hücre, kapı açma ve kapama işlemlerine göre hangi bilgilerin saklanması gerektiğini ve birimlerin bilgilere ne zaman erişmesi gerektiğini belirler. Bi-LSTM, önceki bağlama ek olarak gelecekteki bağlamı yakalamak için ileri ve geri gizli katmanları birleştirir. Sonuç olarak, her iki yönde de daha büyük bir zamansal bilgi akışı vardır ve ağ daha etkili bir şekilde öğrenir.

RNN'ye dayalı bir başka derin sinir ağı mimarisi, Geçitli Tekrarlayan Birimdir (GRU) [23]. Daha önce belirtildiği gibi, LSTM mimarisi, RNN'nin kaybolan gradyan problemini verimli bir şekilde çözer ve uzun süreli hafıza ağırlığı iyi bir şekilde tutulabilir. Ancak LSTM, birçok hesaplama içeren karmaşık bir mimariye sahiptir. Tipik GRU mimarisinde, LSTM mimarisinden farklı olarak, güncelleme kapısı ve sıfırlama kapısı bulunmaktadır.

3.3. Çalışan Bellek Bağlantısı Mekanizması

Çalışan bellek bağlantısı mekanizması, LSTM mimarisinde yer alan bellek hücrelerinin kapılarının değerini bir dizi tekrarlayan ağırlık aracılığıyla etkilemesini sağlayan bir yapıdır [15]. Uygun bir bağlantı tasarımı ile, hücre durumunun LSTM bloğu içerisindeki geçit mekanizmalarını doğrudan etkilemesine olanak verilerek, DDİ görevlerinde metin belgelerinin daha etkin bir biçimde işlenebilmesini olanaklı kolmayı amaçlamaktadır. Geleneksel LSTM tabanlı mimarilerde, geçiş aşağıda verilen denklemlere göre yapılmaktadır [24]:

Çalışan bellek mekanizması tabanlı LSTM mimarisinde, bellek hücrelerinin kapılarının değerini bir dizi tekrarlayan ağırlık aracılığıyla etkilemesini sağlamak amacıyla, Denklem 1, Denklem 2 ve Denklem 3, sırasıyla, Denklem 7, Denklem 8 ve Denklem 9 ile değiştirilmiştir [15]:

$$i_t = \sigma(W^{(i)}x_t + U^{(i)}h_{t-1} + \tanh(W^{(ic)}c_{t-1}) + b^{(i)}) \quad (7)$$

$$f_t = \sigma(W^{(f)}x_t + U^{(f)}h_{t-1} + \tanh(W^{(fc)}c_{t-1}) + b^{(f)}) \quad (8)$$


$$o_t = \sigma(W^{(o)}x_t + U^{(o)}h_{t-1} + \tanh(W^{(oc)}c_t) + b^{(o)}) \quad (9)$$

Burada, $W^{(oc)}c_t$, $W^{(ic)}c_{t-1}$ ve $W^{(fc)}c_{t-1}$ hafıza hücresi ve kapılar arasında bir dizi tekrarlayan ağırlığı modellemek üzere kullanılan doğrusal olmayan bir etkinleştirme işlevini temsil etmektedir.

4. Deneysel Sonuçlar ve Tartışma

Bu bölümde, deneysel süreç, değerlendirme ölçütleri ve çalışmanın deneysel sonuçları ile tartışma sunulmaktadır. Deneysel analizde, Türkçe Twitter mesajlarını içeren bir veri seti kullanılmıştır [25]. Veri seti, terim ağırlıklandırma yöntemlerinin duygu analizindeki etkinliklerini incelemek amacıyla oluşturulmuş bir veri setidir. Veri seti, Twitter API kullanılarak Python'da yazılmış bir uygulama kullanılarak iki aylık bir süre içinde elde edildi. Duygu analizi veri setinde 10500'ü olumlu, 10500'ü olumsuz olmak üzere toplam 21000 Twitter mesajı bulunmaktadır. Veri setinde kök bulma, durdurma kelimelerinin çıkarılması ve kök bulma gibi ön işleme adımları uygulanmıştır. Ham Twitter mesajlarına açıklama eklemek için, her mesajın duygu yönelimine göre iki kategoriden birine atandığı bir açıklama süreci kullandık: olumlu veya olumsuz. Ham mesajlara iki uzman tarafından açıklama yapılmıştır. Cohen'in kapa (κ)

metriği hesaplanmıştır. Derlem için, açıklayıcılar arasında mükemmel bir uyum olduğunu gösteren 0.82'lik bir puan elde edilmiştir. Veri seti oluşturma aşamasında hem olumlu hem de olumsuz bir ifade bildiren Twitter mesajları veri setinden çıkarılmıştır. Ayrıca mesajlardaki harflerin her biri küçük harfe dönüştürülmüş, noktalama işaretleri, sayılar ve '@', '#' gibi özel karakterler kaldırılmıştır. Metin mesajları terimlere ve karakter uzunluğuna göre filtrelenmiş, yineleyen harfler kaldırılmıştır. Etkisiz kelimeleri çıkarmak için Lucene uygulama geliştirme arayüzü, kök bulma aşamasında ise Zemberek kütüphanesi kullanılmıştır. Derin öğrenme mimarilerinin performansını değerlendirmek, doğru sınıflandırma oranı, F-ölçütü, geri çağırma ve hassasiyet ölçütleri ve 5-kat çapraz geçerleme kullanılmıştır. Deneysel parametreler, [15]'teki şekliyle alınmıştır. Bu nedenle, gizli katman boyutu $N=128$ olarak, öğrenme oranı 10^{-2} olarak, batch boyutu 128 olarak alınmıştır. Derin sinir ağı modelleri, gradyan normları 1.0'da kırılacak şekilde 200 epok boyunca eğitilmiştir. Şekil 1'de karşılaştırılan kelime gömme yöntemlerine, farklı vektör boyutlarına, farklı projeksiyon katman boyutlarına ve derin öğrenme mimarilerine ilişkin doğru sınıflandırma oranı temel etki diyagramı sunulmaktadır.



Şekil 1. Karşılaştırılan yöntemlere ilişkin temel etki diyagramı

Tablo 1. Derin öğrenme mimarileri ile elde edilen doğru sınıflandırma oranları

Kelime Gömme Yöntemi	Vektör boyutu	Projeksiyon katmanının boyutu	RNN	LSTM	GRU	LSTM-PH	LSTM-WM
word2vec (Skip-gram)	200	100	85,31	86,01	87,26	88,59	90,93
word2vec (Skip-gram)	200	200	79,12	83,90	86,25	87,85	88,97
word2vec (Skip-gram)	300	100	83,81	84,86	87,02	88,16	90,30
word2vec (Skip-gram)	300	300	83,22	84,79	86,94	88,10	89,89
word2vec (CBOW)	200	100	80,21	84,17	86,56	87,89	88,98
word2vec (CBOW)	200	200	85,07	85,85	87,04	88,37	90,38
word2vec (CBOW)	300	100	83,04	84,66	86,80	88,07	89,59
word2vec (CBOW)	300	300	85,65	86,17	87,51	88,85	93,20
fastText (Skip-gram)	200	100	85,09	85,91	87,12	88,39	90,87
fastText (Skip-gram)	200	200	83,63	84,85	86,99	88,16	90,18
fastText (Skip-gram)	300	100	82,33	84,37	86,74	87,96	89,20
fastText (Skip-gram)	300	300	85,06	85,76	87,03	88,31	90,30
fastText (CBOW)	200	100	83,33	84,81	86,96	88,15	90,02
fastText (CBOW)	200	200	82,70	84,60	86,77	88,03	89,45
fastText (CBOW)	300	100	82,22	84,25	86,62	87,91	89,09
fastText (CBOW)	300	300	85,72	86,24	87,56	88,88	93,36
GloVe	200	100	85,09	85,87	87,09	88,37	90,57
GloVe	200	200	85,52	86,15	87,46	88,83	91,65
GloVe	300	100	85,38	86,05	87,34	88,66	91,37
GloVe	300	300	85,30	85,92	87,17	88,47	90,92

Tablo 2. Derin öğrenme mimarileri ile elde edilen geri çağırma (recall) değerleri

Kelime Gömme Yöntemi	Vektör boyutu	Projeksiyon katmanının boyutu	RNN	LSTM	GRU	LSTM-PH	LSTM-WM
word2vec (Skip-gram)	200	100	0,86	0,87	0,88	0,89	0,92
word2vec (Skip-gram)	200	200	0,80	0,85	0,87	0,89	0,90
word2vec (Skip-gram)	300	100	0,85	0,86	0,88	0,89	0,91
word2vec (Skip-gram)	300	300	0,84	0,86	0,88	0,89	0,91
word2vec (CBOW)	200	100	0,81	0,85	0,87	0,89	0,90
word2vec (CBOW)	200	200	0,86	0,87	0,88	0,89	0,91
word2vec (CBOW)	300	100	0,84	0,86	0,88	0,89	0,90
word2vec (CBOW)	300	300	0,87	0,87	0,88	0,90	0,94
fastText (Skip-gram)	200	100	0,86	0,87	0,88	0,89	0,92
fastText (Skip-gram)	200	200	0,84	0,86	0,88	0,89	0,91
fastText (Skip-gram)	300	100	0,83	0,85	0,88	0,89	0,90
fastText (Skip-gram)	300	300	0,86	0,87	0,88	0,89	0,91
fastText (CBOW)	200	100	0,84	0,86	0,88	0,89	0,91
fastText (CBOW)	200	200	0,84	0,85	0,88	0,89	0,90
fastText (CBOW)	300	100	0,83	0,85	0,87	0,89	0,90
fastText (CBOW)	300	300	0,87	0,87	0,88	0,90	0,94
GloVe	200	100	0,86	0,87	0,88	0,89	0,91
GloVe	200	200	0,86	0,87	0,88	0,90	0,93
GloVe	300	100	0,86	0,87	0,88	0,90	0,92
GloVe	300	300	0,86	0,87	0,88	0,89	0,92

Tablo 3. Derin öğrenme mimarileri ile elde edilen hassasiyet oranı değerleri

Kelime Gömme Yöntemi	Vektör boyutu	Projeksiyon katmanının boyutu	RNN	LSTM	GRU	LSTM-PH	LSTM-WM
word2vec (Skip-gram)	200	100	0,87	0,88	0,89	0,90	0,93
word2vec (Skip-gram)	200	200	0,81	0,86	0,88	0,90	0,91
word2vec (Skip-gram)	300	100	0,86	0,87	0,89	0,90	0,92
word2vec (Skip-gram)	300	300	0,85	0,87	0,89	0,90	0,92
word2vec (CBOW)	200	100	0,82	0,86	0,88	0,90	0,91
word2vec (CBOW)	200	200	0,87	0,88	0,89	0,90	0,92
word2vec (CBOW)	300	100	0,85	0,86	0,89	0,90	0,91
word2vec (CBOW)	300	300	0,87	0,88	0,89	0,91	0,95
fastText (Skip-gram)	200	100	0,87	0,88	0,89	0,90	0,93
fastText (Skip-gram)	200	200	0,85	0,87	0,89	0,90	0,92
fastText (Skip-gram)	300	100	0,84	0,86	0,89	0,90	0,91
fastText (Skip-gram)	300	300	0,87	0,88	0,89	0,90	0,92
fastText (CBOW)	200	100	0,85	0,87	0,89	0,90	0,92
fastText (CBOW)	200	200	0,84	0,86	0,89	0,90	0,91
fastText (CBOW)	300	100	0,84	0,86	0,88	0,90	0,91
fastText (CBOW)	300	300	0,87	0,88	0,89	0,91	0,95
GloVe	200	100	0,87	0,88	0,89	0,90	0,92
GloVe	200	200	0,87	0,88	0,89	0,91	0,94
GloVe	300	100	0,87	0,88	0,89	0,90	0,93
GloVe	300	300	0,87	0,88	0,89	0,90	0,93

Tablo 4. Derin öğrenme mimarileri ile elde edilen F-ölçütü değerleri

Kelime Gömme Yöntemi	Vektör boyutu	Projeksiyon katmanının boyutu	RNN	LSTM	GRU	LSTM-PH	LSTM-WM
word2vec (Skip-gram)	200	100	0,87	0,87	0,89	0,90	0,92
word2vec (Skip-gram)	200	200	0,80	0,85	0,88	0,89	0,90
word2vec (Skip-gram)	300	100	0,85	0,86	0,88	0,90	0,92
word2vec (Skip-gram)	300	300	0,84	0,86	0,88	0,89	0,91
word2vec (CBOW)	200	100	0,81	0,85	0,88	0,89	0,90
word2vec (CBOW)	200	200	0,86	0,87	0,88	0,90	0,92
word2vec (CBOW)	300	100	0,84	0,86	0,88	0,89	0,91
word2vec (CBOW)	300	300	0,87	0,87	0,89	0,90	0,95
fastText (Skip-gram)	200	100	0,86	0,87	0,88	0,90	0,92
fastText (Skip-gram)	200	200	0,85	0,86	0,88	0,89	0,92
fastText (Skip-gram)	300	100	0,84	0,86	0,88	0,89	0,91
fastText (Skip-gram)	300	300	0,86	0,87	0,88	0,90	0,92
fastText (CBOW)	200	100	0,85	0,86	0,88	0,89	0,91
fastText (CBOW)	200	200	0,84	0,86	0,88	0,89	0,91
fastText (CBOW)	300	100	0,83	0,86	0,88	0,89	0,90
fastText (CBOW)	300	300	0,87	0,88	0,89	0,90	0,95
GloVe	200	100	0,86	0,87	0,88	0,90	0,92
GloVe	200	200	0,87	0,87	0,89	0,90	0,93
GloVe	300	100	0,87	0,87	0,89	0,90	0,93
GloVe	300	300	0,87	0,87	0,88	0,90	0,92

Derin öğrenme algoritmaları ile elde edilen doğru sınıflandırma oranı, geri çağırma, hassasiyet ve F-ölçütü değerleri sırasıyla Tablo 1, Tablo 2, Tablo 3 ve Tablo 4'te sunulmaktadır. Deneysel analizler, çalışan bellek bağlantıları tabanlı uzun kısa süreli bellek mimarisinin (LSTM-WM) Türkçe metin belgeleri üzerinde duygu analizi için, gözetleme deliği tabanlı uzun kısa süreli bellek mimarisi (LSTM-PH), uzun kısa süreli bellek ve geçitli tekrarlayan birim mimarisine kıyasla daha yüksek doğru sınıflandırma oranı elde ettiğini göstermektedir. GloVe kelime gömme yönteminin diğer kelime gömme yöntemlerine kıyasla daha iyi sonuçlar aldığı görülmektedir. Vektör boyutunu 300 olarak almanın daha iyi sonuçlar verdiği görülmektedir. Karşılaştırılan derin öğrenme mimarileri arasında en düşük başarımlı, tekrarlayan sinir ağı mimarisi (RNN) ile en yüksek başarımlı ise çalışan bellek bağlantıları tabanlı uzun kısa süreli bellek mimarisi ile elde edilmektedir.

5. Sonuç

Metin sınıflandırma, metin belgelerinin önceden belirlenmiş sınıf etiketlerinden birine atanmasına yönelik bir doğal dil işleme alanıdır. Metin sınıflandırma, aralarında duygu analizi, konu etiketleme, soru yanıtlama ve diyalog eylemi sınıflandırmanın da yer aldığı birçok doğal dil işleme probleminde kullanılmaktadır. Metin sınıflandırma, haber metinlerinin filtrelenmesi ve organizasyonu, istenmeyen e-posta içeriklerinin filtrelenmesi gibi birçok uygulama alanına sahiptir. Son yıllarda, metin sınıflandırma alanında, derin sinir ağı tabanlı mimariler ve sinirsel dil modelleri sıklıkla kullanılmaktadır. Uzun kısa süreli bellek tabanlı mimariler (LSTM), uzun süreli bağımlılıkları öğrenirken, geleneksel tekrarlayan sinir ağlarında gözlemlenen patlayan ve kaybolan gradyanları azaltmak için geçit mekanizmalarını kullanır. Bu nedenle, LSTM ve türevi mimariler, birçok dizi modelleme görevinde yaygın kullanıma sahiptir. LSTM tabanlı mimarilerde, bellek hücresi temel bilgileri içermesine karşın, geçit mekanizmasını doğrudan etkilemesine izin verilmez. Bu çalışmada, Türkçe duygu analizi için, tekrarlayan sinir ağı, uzun kısa süreli bellek, geçitli tekrarlayan birim, gözetleme deliği tabanlı uzun kısa süreli bellek mimarisi ve çalışan bellek bağlantıları tabanlı uzun kısa süreli bellek mimarisinin başarımlı karşılaştırmalı olarak değerlendirilmektedir. Deneysel analizler, çalışan bellek bağlantıları tabanlı uzun kısa süreli bellek mimarisinin (LSTM-WM) Türkçe metin belgeleri üzerinde duygu analizi için, gözetleme deliği tabanlı uzun kısa süreli bellek mimarisi (LSTM-PH), uzun kısa süreli bellek ve geçitli tekrarlayan birim mimarisine kıyasla daha yüksek doğru sınıflandırma oranı elde ettiğini göstermektedir. GloVe kelime gömme yönteminin diğer kelime gömme yöntemlerine kıyasla daha iyi sonuçlar aldığı görülmektedir. Vektör boyutunu 300 olarak almanın daha iyi sonuçlar verdiği görülmektedir. Karşılaştırılan derin öğrenme mimarileri arasında en düşük başarımlı, tekrarlayan sinir ağı mimarisi (RNN) ile en yüksek başarımlı ise çalışan bellek bağlantıları tabanlı uzun kısa süreli bellek mimarisi ile elde edilmektedir.

Kaynakça

1. Li, Q., Peng, H., Li, J., Xia, C., Yang, R., Sun, L., ... & He, L. (2020). A survey on text classification: From shallow to deep learning. *arXiv preprint arXiv:2008.00364*.

2. Onan, A., Korukoğlu, S., & Bulut, H. (2016). Ensemble of keyword extraction methods and classifiers in text classification. *Expert Systems with Applications*, 57, 232-247.

3. Fersini, E., Messina, E., & Pozzi, F. A. (2014). Sentiment analysis: Bayesian ensemble learning. *Decision support systems*, 68, 26-38.

4. Onan, A., Korukoğlu, S., & Bulut, H. (2016). A multiobjective weighted voting ensemble classifier based on differential evolution algorithm for text sentiment classification. *Expert Systems with Applications*, 62, 1-16.

5. Medhat, W., Hassan, A., & Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams engineering journal*, 5(4), 1093-1113.

6. Onan, A., & Korukoğlu, S. (2016). Makine öğrenmesi yöntemlerinin görüş madenciliğinde kullanılması üzerine bir literatür araştırması. *Pamukkale University Journal of Engineering Sciences*, 22(2).

7. Chatterjee, A., Gupta, U., Chinnakotla, M. K., Srikanth, R., Galley, M., & Agrawal, P. (2019). Understanding emotions in text using deep learning and big data. *Computers in Human Behavior*, 93, 309-317.

8. Almeida, F., & Xexéo, G. (2019). Word embeddings: A survey. *arXiv preprint arXiv:1901.09069*.

9. Zhang, L., Wang, S., & Liu, B. (2018). Deep learning for sentiment analysis: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4), e1253.

10. Xu, J., Chen, D., Qiu, X., & Huang, X. (2016). Cached long short-term memory neural networks for document-level sentiment classification. *arXiv preprint arXiv:1610.04989*.

11. Rao, G., Huang, W., Feng, Z., & Cong, Q. (2018). LSTM with sentence representations for document-level sentiment classification. *Neurocomputing*, 308, 49-57.

12. Al-Smadi, M., Talafha, B., Al-Ayyoub, M., & Jararweh, Y. (2019). Using long short-term memory deep neural networks for aspect-based sentiment analysis of Arabic reviews. *International Journal of Machine Learning and Cybernetics*, 10(8), 2163-2175.

13. Lu, C., Huang, H., Jian, P., Wang, D., & Guo, Y. D. (2017, May). A P-LSTM neural network for sentiment classification. In *Pacific-Asia Conference on Knowledge Discovery and Data Mining* (pp. 524-533). Springer, Cham.

14. Ma, Y., Peng, H., Khan, T., Cambria, E., & Hussain, A. (2018). Sentic LSTM: a hybrid network for targeted aspect-based sentiment analysis. *Cognitive Computation*, 10(4), 639-650.

15. Landi, F., Baraldi, L., Cornia, M., & Cucchiara, R. (2021). Working memory connections for LSTM. *Neural Networks*, 144, 334-341.

16. Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*.

17. Onan, A., & Toçoğlu, M. A. (2021). Weighted word embeddings and clustering-based identification of question topics in MOOC discussion forum posts. *Computer Applications in Engineering Education*, 29(4), 675-689.

18. Bojanowski, P., Grave, E., Joulin, A., & Mikolov, T. (2017). Enriching word vectors with subword information. *Transactions of the association for computational linguistics*, 5, 135-146.

19. Pennington, J., Socher, R., & Manning, C. D. (2014, October). Glove: Global vectors for word representation. In *Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)* (pp. 1532-1543).
20. Gutiérrez, G., Canul-Reich, J., Zezzatti, A. O., Margain, L., & Ponce, J. (2018). Mining: Students comments about teacher performance assessment using machine learning algorithms. *International Journal of Combinatorial Optimization Problems and Informatics*, 9(3), 26.
21. Li, X., & Wu, X. (2015, April). Constructing long short-term memory based deep recurrent neural networks for large vocabulary speech recognition. In *2015 IEEE International conference on acoustics, speech and signal processing (icassp)* (pp. 4520-4524). IEEE.
22. Li, X., Peng, L., Yao, X., Cui, S., Hu, Y., You, C., & Chi, T. (2017). Long short-term memory neural network for air pollutant concentration predictions: Method development and evaluation. *Environmental pollution*, 231, 997-1004.
23. Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*.
24. Rojas-Barahona, L. M. (2016). Deep learning for sentiment analysis. *Language and Linguistics Compass*, 10(12), 701-719.