



# Derin öğrenme yöntemleri ve kelime yerleştirme modelleri kullanılarak Parkinson hastalığının duygu analiziyle değerlendirilmesi

## The evaluation of Parkinson's disease with sentiment analysis using deep learning methods and word embedding models

Feyza CEVİK<sup>1</sup>, Zeynep Hilal KİLİMCİ<sup>2\*</sup>

<sup>1</sup>IQ Bender Teknoloji Şirketi, İstanbul, Türkiye.

feyza.cevik@iqbender.com

<sup>2</sup>Bilişim Sistemleri Mühendisliği, Kocaeli Üniversitesi, Kocaeli, Türkiye.

oacel.kilimci@kocaeli.edu.tr

Geliş Tarihi/Received: XX.XX.20XX  
Kabul Tarihi/Accepted: XX.XX.20XX

Düzeltilme Tarihi/Revision: XX.XX.20XX

doi: 10.5505/pajes.20XX.XXXXX  
Araştırma Makalesi/Research Article

### Öz

Parkinson hastalığı, hastanın yaşam kalitesini etkileyen, önemli sosyal ve ekonomik etkileri olan ve semptomların aşamalı görünümü nedeniyle erken teşhis edilmesi güç olan yaygın bir nörolojik hastalıktır. Parkinson hastalığının Twitter gibi sosyal medya platformlarında tartışılması, hastaların Parkinson hastalığının hem tanı hem de tedavi aşamasında birbirleriyle iletişim kurduğu bir platform sağlar. Bu çalışmanın amacı, derin öğrenme ve kelime yerleştirme modellerini kullanarak insanların Parkinson hastalığı ile ilgili duygu analizlerini değerlendirmek ve karşılaştırmaktır. Bildiğimiz kadarıyla, bu çalışma Parkinson hastalığını sosyal medya aracılığıyla kelime yerleştirme modelleri ve derin öğrenme algoritmaları kullanarak analiz etmek için yapılan ilk çalışmadır. Bu çalışmada, kelime yerleştirme modelleri olarak Word2Vec, GloVe ve FastText; Evrimsel Sinir Ağları (CNN'ler), Tekrarlayan Sinir Ağları (RNN'ler) ve Uzun Kısa Süreli Bellek Ağları (LSTM'ler) derin öğrenme teknikleri olarak harmanlanmış ve sınıflandırma amacıyla kullanılmıştır. Kelime yerleştirme modelleri ve derin öğrenme algoritmaları kullanılarak Parkinson hastalığı hakkında kullanıcı yorumlarının duygularını analiz etmek amacıyla kapsamlı deneyler İngilizce Twitter veri kümesi üzerinde gerçekleştirilmiştir. Deney sonuçlarında, Word2Vec kelime yerleştirme modelinin CNN derin öğrenme algoritmasıyla harmanlanması sonucu %75.12 doğruluk ile kayda değer bir sınıflandırma başarısı gözlemlenmiştir. Bu çalışma, hastaların gereksinimlerini anlamak için kelime yerleştirme modelleri ve derin öğrenme algoritmalarını kullanma etkinliğini ve Parkinson hastalarının ve yakınlarının duygularını sosyal medya aracılığı ile analiz ederek tedavi sürecine değerli bir katkı sağladığını göstermektedir.

**Anahtar kelimeler:** Parkinson hastalığı, Duygu analizi, Derin öğrenme modelleri, Kelime yerleştirme yöntemleri

### Abstract

Parkinson's disease is a common neurodegenerative neurological disorder, which affects the patient's quality of life, has significant social and economic effects, and is difficult to diagnose early due to the gradual appearance of symptoms. Examining the discussion of Parkinson's disease in social media platforms such as Twitter provides a platform where patients communicate each other in both diagnosis and treatment stage of the Parkinson's disease. The purpose of this work is to evaluate and compare the sentiment analysis of people about Parkinson's disease by using deep learning and word embedding models. To the best of our knowledge, this is the very first study to analyze Parkinson's disease through social media by using word embedding models and deep learning algorithms. In this study, Word2Vec, GloVe, and FastText as word embedding models and Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs), and Long Short Term Memory Networks (LSTMs) as deep learning techniques are blended and used for classification purpose. Extensive experiments are conducted to analyze the sentiments of user comments about Parkinson's disease using word embedding models and deep learning algorithms on English Twitter dataset. The remarkable classification success with 75.12% of accuracy is observed in the experiments through the result of blending Word2Vec as a word embedding model and CNN as a deep learning technique. This study demonstrates the effectiveness of using word embedding models and deep learning algorithms to understand patients' needs, and provides a valuable contribution to the treatment process by analyzing the feelings of Parkinson's patients and their relatives through social media.

**Keywords:** Parkinson's disease, Sentiment analysis, Deep learning models, Word embedding methods.

## 1 Giriş

Son yıllarda internet ve mobil teknolojinin gelişmesiyle birlikte, sosyal medya platformları hızla büyüdü. İnternet, hastaları ve akrabalarını hastalık süreci hakkında bilgilendirmek, görüş ve deneyimlerini paylaşmak ve tedavi seçenekleri hakkında ayrıntılı bilgi edinmek için önemli bir kaynak haline gelmiştir [1]. Twitter, bilgilerin olduğu gibi paylaşıldığı ve gerçek zamanlı olarak başkalarıyla bağlantı kurulabilen en popüler sosyal ağ hizmetidir [2],[3]. Aylık, yaklaşık 350 milyon aktif Twitter kullanıcısı ile Twitter, gerçek dünya hakkında bilgi toplamak için güçlü bir araçtır [4]. Twitter, aynı zamanda hastaların ve hasta yakınlarının deneyimlerini paylaştığı ve duygularını

anlamalarına olanak sağladığı güçlü bir sağlık veri kaynağıdır [5]-[7].

Sentiment Analiz (Duygu/duyarlılık analizi), konuşma veya yazma gibi öznel bir dil ögesinin belirli bir konuda pozitif veya negatif olarak kutuplaşmasıdır. Sınıflandırma her zaman pozitif veya negatif olmayabilir, ancak kullanılacak soruna veya verilere bağlı olarak çok pozitif, pozitif, nötr, negatif, çok negatif gibi sınıflarla detaylandırılabilir. Otomatik duygu analizi, öznel bilgi istatistiklerine ulaşmak isteyen bir birimin metinler aracılığıyla analiz yapmasını amaçlar.

Parkinson hastalığı (PD), merkezi sinir sisteminin dünya çapında 10 milyondan fazla insanı etkileyen, yaşam kalitesini,

\*Yazışılan yazar/Corresponding author

motor refleksini, konuşmasını, davranışını, zihinsel sürecini ve diğer hayati fonksiyonlarını etkileyen nörodejeneratif bir hastalıktır [8],[9]. Parkinson hastalarında titreme belirtileri, yavaş hareket, kas sertliği ve denge kaybı gibi birçok semptom vardır. Bu semptomlara ek olarak, zihinsel değişiklikler, konuşma bozuklukları, uyku bozuklukları ve depresyon belirtileri de sıklıkla gözlenir ve bu semptomlar zamanla kötüleşebilir. Konuşma bozuklukları hastaların yaklaşık yüzde 90' ında görülür. Ek olarak, bu hastalar düşük ses, donuk konuşma, konuşmaya başlamada zorluk, gürültüyü sürdürmede zorluk, telaffuzda hata ve akıcılığın azalması gibi konuşma bozukluğu belirtileri içerebilir [9]. Parkinson, tipik olarak 40-70 yaşları arasında görülür ve yaş ilerledikçe görülme sıklığı artış gösterir. Hastaların %75 kadarında ilk semptomlar, 60 yaşından sonra ortaya çıkmaktadır. Epidemiyolojik araştırmalarda yaş ve cinsiyet haricinde semptomların yanında diğer risk durumları arasında beyaz ırk, aile öyküsünde Parkinson hastalığı olması, kafa travması, karbonmonoksit, ağır metaller ve tarım ilaçları gibi çeşitli toksik maddelere maruz kalınması, kuyu suyu içimi ve kırsal kesimde yaşama gibi durumlar söz konusudur.

Derin öğrenme (DL) algoritmaları ve kelime yerleştirme (WE) modellerinin uygulanması son yıllarda görüntü işleme (Image Processing), görüntü sınıflandırma (Image Classification), nesne bulma (Object Detection), nesne takip etme (Object Tracking), doğal dil işleme (Natural Language Processing), stil transferi (Style Transferring) ve makine çevirisi gibi farklı araştırma alanlarında çok popülerdir. DL yöntemleri ve WE modelleri, geleneksel makine öğrenmesi algoritmalarına kıyasla daha iyi tahminler ve sonuçlar sunması nedeniyle araştırmacılar tarafından tercih edilmektedir [10]-[18]. Derin öğrenme modelleri temel olarak, derin sinir ağları aracılığıyla verilerin anlamlı bir şekilde temsil edilmesini sağlamak için karmaşık özellikleri minimal dış destekle eğiterek otomatik özellik çıkarımı sağlamak için kullanılır. Ayrıca, birçok alanda sınıflandırma görevlerinde derin öğrenme yöntemleri de kullanılmaktadır. Evrişimli sinir ağları (CNN'ler) [17],[18], tekrarlayan sinir ağları (RNN'ler) [10],[12],[14] uzun kısa süreli bellek ağları (LSTM'ler) [12],[18], derin inanç ağları (DBN'ler) derin öğrenme modelleri olarak ve Word2Vec [13],[15], GloVe [16], FastText [11] kelime yerleştirme modelleri olarak tanınmış mimarilerdir.

Bu çalışmada, Parkinson hastaları için kişisel bir bakım planının geliştirilmesini kolaylaştırmayı ve bireysel ve örgütsel kullanıcıların duygularını analizini kullanarak, artan bir Parkinson hasta popülasyonuna kişisel sağlık bilgileri için değerli bir tıbbi kaynak sağlamayı öneriyoruz. Bu amaçla, Parkinson hastalığı ile ilgili tweet'lerin anlamlarını ve bağlamlarını zenginleştirmek için Word2Vec, GloVe ve FastText adlı üç farklı kelime yerleştirme modeli kullanılmaktadır. Ayrıca, bireysel ve örgütsel kullanıcıların tweetlerini yorumlamak ve pozitif, negatif ve tarafsız gibi tweetleri sınıflandırarak Parkinson hastalığı algısını anlamak için derin öğrenme modelleri kullanılmaktadır. Bildiğimiz kadarıyla, bu, derin öğrenme ve kelime yerleştirme temelli modelleri kullanarak Parkinson hastalığına ilişkin duyguları analiz etmeye yönelik ilk girişimdir. Deney sonuçları, Word2Vec kelime yerleştirme modelinin derin öğrenme algoritmasıyla harmanlanması sonucu %75.12 doğruluk ile kayda değer bir sınıflandırma başarısı göstermektedir.

Makalenin geri kalanı şu şekilde düzenlenmiştir: Bölüm 2, Parkinson hastalığı ile ilgili yapılan çalışmaların bir özeti

sunar. Sistem modeli ve sonuçlar Bölüm 3 ve 4' te verilmektedir.

## 2 Literatür Çalışmaları

Bu bölüm, Parkinson Hastalığı (PD) hakkındaki çalışmaların literatür taramasının kısa bir özeti sunar.

Bir çalışmada yazarlar, Probabilistic Neural Network (PNN) sınıflandırıcısı, Parkinson hastalığının tanısı için kullanılır ve %80.92' lik test başarısı elde eder. Bu çalışmada kullanılan veri seti 23' ü Parkinson hastalığı olan 31 denekten alınan çeşitli biyomedikal ses ölçümlerinden oluşmaktadır [19]. Voulodimos ve ark., Parkinson hastalarından (42 kişi) oluşan ve hasta başına yaklaşık 200 ses kaydı içeren Parkinson veri kümesinin sınıflandırılmasına odaklanmışlardır. Destek vektör makinesi, önerilen modelin sınıflandırıcısı olarak kullanılır. Öte yandan, filtre seçiminde ilgisiz ölçüm özellikleri seçmek için kullanılır. Deney sonuçları, önerilen modelin sınıflandırma performansının %91.40 başarı oranına ulaştığını göstermektedir [20]. Başka bir çalışmada, konvansiyonel önyüklemeye ya da bir-bir-dışa doğrulama validasyon yöntemi ve karşılıklı olarak bilgiye dayalı bir nitelik seçimi metodu (maksimum alaka düzeyi minimum yedeklilik - MRMR) tarafından toplanan özellikleri kullanır. PD veri seti, 195 denekten oluşan 32 kişinin (24 PD ve 8 sağlıklı) ses kayıtlarından meydana gelmiştir ve %92.9 doğruluk performansı rapor edilmiştir [21]. Başka bir çalışmada, Parkinson hastalarını ayırt etmek için sinir ağları, veri madenciliği sinir ağları modeli (DMneural), regresyon ve karar ağacı olmak üzere dört bağımsız sınıflandırma modeli uygulanmıştır. Sinirsel ağ tabanlı sınıflandırıcı %92.9 doğruluk sonucuyla diğerlerinden daha iyi performans gösterir [22]. Çağlar ve ark., hem sınıflandırma görevi hem de özellik seçimi için insan biyomedikal sesini içeren Parkinson hastalığı veri kümesi örneklerinde dilsel olarak güçlü adaptif sinir bulanık sınıflandırıcı (ANFC + LH) kullanılmaktadırlar. ANFC + LH kullanımının 94.72 sınıflandırma performansı gösterdiği rapor edilmiştir [23].

Başka bir çalışmada, Parkinson hastalığının sınıflandırılması, bulanık C-ortalama kümelemesi temelinde özellik ağırlıklandırma yöntemi kullanılarak önerilmiştir. PD veri seti, Kaliforniya Üniversitesi Irvine makine öğrenim veri tabanından elde edilmiştir. Veri kümesinin içeriği, 31'i erkek, 23'ü kadın PD tanısı alan 195 uzun vadeli sesli fondu oluşmaktadır. Ağırlıklandırılmış Parkinson hasta veri kümesi için k-NN sınıflandırma algoritması kullanılarak farklı k değerleri için %97.93'lük bir başarı oranı elde edilmiştir [24]. Diğer bir çalışmada, dört tıbbi veri seti, dermatoloji, Pima-Hint diyabeti, meme kanseri ve Parkinson veri kümesi kullanılarak, benzerlik sınıflandırıcısı (SC) ve bulanık entropi (FE) özellik seçim yöntemleriyle %85.03 sınıflandırma performansı elde edilmiştir [25]. Diğer bir çalışmada yazarlar, yapay bağışıklık sistemi (AIS) ve klon niteliği seçim yaklaşımlarını kullanarak Parkinson hastalığının tanınmasına odaklanılmaktadır. Bu amaçla, veri kümesi, yukarıda belirtilen çalışmaların çoğunda olduğu gibi Oxford Üniversitesi' nde, Ulusal Ses ve Konuşma Merkezi, Denver, Colorado ile iş birliği içinde oluşturulmuştur. Yazarlar AIS kullanımının %92.70 sınıflandırma başarısı sağladığını bildirmektedirler [26]. Başka bir çalışma, Parkinson hastalığının tanısı için özellik seçim yöntemlerinin vokal ölçümlerden karşılaştırılmasına odaklanılmaktadır. Bu amaçla, SVM sınıflandırıcısı altı farklı özellik seçim yöntemiyle harmanlanmıştır. Parkinson hastalığı veri kümesi ve birleşik Parkinson hastalığı veri kümesi, iki Parkinson hastalığı veri kümesi grubu, Parkinson hastalığının

tanısında biyomedikal ses parametreleri kullanılarak test edilmiştir. Deney sonuçları, özyinelemeli özellik elemeli (SVM-RFE) özellik seçim yöntemine dayanan destek vektör makinesi yöntemlerinin, önerilen sistemin sınıflandırma başarısını diğerlerine göre %95.13 doğruluk değeriyle artırdığını göstermiştir [27].

Başka bir çalışmada [28] yazarlar, Parkinson hastalığında klinik ölçekler ve makine öğrenme modelleri kullanarak yeni ve geliştirilmiş aşama tahmini önermişlerdir. Lojistik regresyon (OLR), destek vektör makinesi (SVM), Adaptif Boost (AdaBoost) ve Random Under sampling Boosting (RUSBoost) tabanlı sınıflandırıcılar gibi makine öğrenme tekniklerini kullanarak PD'nin aşamasını ve ciddiyetini tahmin etmek için tahmin modelleri geliştirmişlerdir. Ek olarak, PD veri kümesindeki özelliklerin önemi rastgele ormanlar kullanılarak belirlenmiştir. AdaBoost tabanlı topluluk modeli %97.46 ile en yüksek sınıflandırma sonucunu sunmuştur. Başka bir çalışmada [29], yazarlar hasta anketi ve prediktif modelleme yoluyla Parkinson hastalığının erken saptanmasına odaklanmışlardır. Bu amaçla, hareket bozukluğu toplum-birleşik Parkinson hastalığı derecelendirme ölçeğinden (MDS-UPDRS) gelen hasta anketi veri kümesi olarak kullanılmıştır. Kişiyi sağlıklı, normal ve erken olarak sınıflandırabilecek modelleri tahmin etmek için, lojistik regresyon, destek vektör makinesi, ağaçları artırma, rastgele ormanlar gibi yaygın olarak kullanılan makine öğrenme tekniklerini kullanmışlardır. Bu tekniklerin, erken PD sınıflamasında ROC eğrisi altında (her ikisinde > %95) yüksek doğruluk ve performans gösterdiğini bildirmişlerdir. Bu çalışma ile, bu tahmin modellerinin, bir anketin maddelerini makine öğrenmesi yoluyla birleştirerek uzmanların teşhis sürecine yardımcı olma potansiyeline sahip olduğu sonucuna varılmıştır.

Oscar ve ark. [30], çalışmamıza benzer şekilde Twitter ortamından elde edilen verilerle çalışmaktadırlar. Oscar ve ark. çalışmalarında sadece atılan tweetlerin polaritesini ölçümlerken, bizim çalışmamız hem atılan tweetlerdeki duygu analizini yapmakta hem de atılan tweetler üzerinde doğruluk ölçüm metriğiyle sınıflandırma yapıp gerçekte ne kadar doğruluk ile duygunun saptandığını belirlemektedir. Ayrıca, Oscar ve ark. çalışmamızdan farklı olarak Parkinson hastalığına değil de Alzheimer hastalığı üzerine atılan yorumları analiz etmişlerdir. Literatürdeki birçok çalışma İngilizce metinlerdeki duygu analizini saptarken İnan ve ark. [31], geliştirdikleri model ile Türkçe metinler üzerindeki duygu polaritesini bulmayı hedeflemişlerdir. Metinlerdeki gizlenen duygunun saptanması için çok çeşitli duygu analizi araçları olsa da bu araçların Türkçe dili için duygu polaritesini doğru bir biçimde saptaması söz konusu değildir. Bunun için kullanıcının ekstra olarak platforma önceden eğitilmiş bir Türkçe veri kümesi sunması gereklidir. İnan ve ark. geliştirdikleri modelde Türkçe veri kümesi kullanılacak çalışmalarda, bu zorunluluğu ortadan kaldırmışlar.

Bir başka çalışmada [32] yazarlar, derin öğrenme yaklaşımlarını kullanarak Türkçe metinlerden anlamsal çıkarımlarda bulunmuşlardır. Türkçe metinleri toplamak için çeşitli kategorilerde ürün satışı yapan bir internet sitesini kullanmışlardır. Bu siteden toplanan metinleri analiz ederek pozitif ve negatif anlam içeren kelimelerin vektör temsillerini öğrenerek Word2Vec modelinde eğitmişlerdir. Eğitilmiş olan kelime kümeleri kullanılarak Rastgele Orman (Random Forest-RF) modeli geliştirilmiştir. Klasik tekniklere ek olarak, derin öğrenme yaklaşımlarından LSTM ve CNN modelleri duygu sınıflandırma için kullanılmıştır. Sonuç olarak CNN modeline

göre LSTM modelinin %94.21 daha iyi sonuç ürettiği görülmüştür.

Krizhevsky ve ark. [33], yapay sinir ağı modelinin cümle ve belge modellemesine dikkat çekmişlerdir. Çalışmalarında CNN ve RNN isimli iki temel modeli doğal dilleri anlamada kullanmışlardır. Bu iki mimarinin güçlü yönlerini birleştirmişlerdir. Mimariler duygu sınıflandırması ve soru sınıflandırması görevleri üzerinde değerlendirilmiştir. Deneysel sonuçlar, iki modelin birlikte kullanıldığı yeni model olan C-LSTM'in daha iyi bir performans gösterdiğini ortaya koymuştur. Liu ve ark. [34], 16 farklı metin veri kümesi kullanarak sınıflandırmayı LSTM modeli ile gerçekleştirmişlerdir.

Çalışmamız, yukarıda bahsedilen literatür çalışmalarından farklıdır; bunun sebebi Parkinson hastalığının algı ve duygu analizini, derin öğrenme algoritmaları ve kelime yerleştirme modelleri kullanarak sosyal medya platformu aracılığıyla saptamaya yönelik ilk girişim olmasıdır. Literatür araştırmalarından farklı olarak, Parkinson hastaları için kişisel bir bakım planının geliştirilmesini kolaylaştırmayı ve sosyal medyadan gelen metin verilerini kullanarak, artan bir Parkinson hasta popülasyonuna kişisel sağlık bilgileri için değerli bir tıbbi kaynak sağlamayı önermekteyiz.

### 3 Sistem modeli

Yöntemler, kullanılan araçlar ve önerilen model bu bölümde sunulmaktadır.

#### 3.1 Veri Toplama ve Önerilen Çerçeve

Bu çalışmada, Parkinson hastalığı ile ilgili gönderilen kullanıcı yorumlarının duygu analizlerini değerlendirerek Parkinson hastalığının saptanmasına odaklandık. Bu amaçla, Selenium tarayıcısı, Parkinson hastalığı ile ilgili olarak aşağıdaki anahtar kelimelerden oluşan kullanıcı yorumlarını toplamak için kullanılmaktadır: "Parkinson", "ParkinsonDisease", "ParkinsonsCure", "ParkinsonsTreatment", "ParkinsonDiagnosis", "ParkinsonSymptom". Twitter' da bireysel ve organizasyonel olmak üzere iki ana kullanıcı hesabı vardır. Parkinson hastalarının ve akrabalarının Parkinson hastalığı hakkındaki görüş ve deneyimlerini anlamak ve yorumlamak için Twitter' da tweet adı verilen bireysel ve kurumsal kullanıcı yorumları toplanmaktadır. Bireysel hesaplar hem Parkinson hastalarına hem de onların yakınlarına ait olabilirken, organizasyon hesapları nörologları, haber kaynaklarını ve hasta olmayanları içerebilir. Bu çalışmada, bazı bireysel hesapların korunan tweetleri nedeniyle halka açık bireysel hesaplar analiz edilmiştir. Toplamda 11.043 tweet hem bireysel hem de kurumsal hesaplardan indirilmiştir. Selenium kullanarak, Twitter API' sinin izin verdiği sınır sorunu hakkında endişelenmeden istenildiği kadar tweet toplanabilmiştir. Bu çalışmada, denetimli makine öğrenme stratejisine odaklanılmıştır. Her kullanıcının Parkinson hastalığına karşı tutumunu belirlemek için kullanıcılardan gönderilen her tweeti pozitif, negatif veya nötr olarak etiketleme ihtiyacı vardır. Bu çalışmada, her yoruma ait duygunun belirlenmesi için TextBlob platformu [35] içinde yer alan Naive Bayes sınıflandırıcısı kullanılmıştır. Böylece, her tweet için pozitif, negatif veya nötr olarak sınıf olasılığını oluşturulmuştur. TextBlob' ın yanı sıra pozitif, negatif ve nötr duygu polaritesini belirlemek amacıyla ücretsiz olarak sunulan VADER [40], MonkeyLearn [41] gibi çeşitli duygu analizi araçları bulunmaktadır. Bu çalışmada kullanılan etiketlenmemiş veriler, TextBlob, VADER, ve MonkeyLearn araçlarının uygulama programlama arayüzü (API) ile Python programlama dilinde etiketlenmiş ve

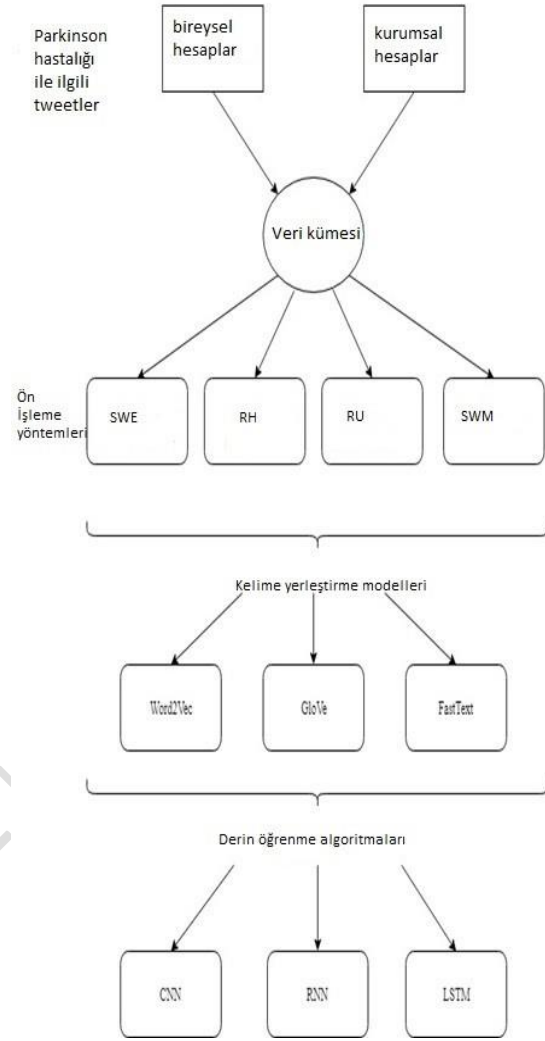
sınıflandırma performansları kıyaslanmıştır. Kullanıcı yorumlarını anlamada TextBlob platformu ile ortalama %79.13 sınıflandırma başarıları sunulurken VADER ve MonkeyLearn ortamlarından sırasıyla %80.37 ve %78.25 doğruluk sonuçları elde edilmiştir. Her bir platformdan farklı doğruluk sonuçlarının elde edilmesinin sebebi farklı sınıflandırıcıların ve ön işleme yöntemlerinin kullanılıyor olmasındandır. Tablo 1’ de pozitif, negatif veya nötr olarak etiketlenen yorumlardan birkaç örnek sunulmaktadır.

Tablo 1 : Ön işleme modellerinin kelime yerleştirme yöntemlerine göre doğruluk sonuçları.

Tweet	Etiket
1) Please don't give unsolicited and inane advice and instead just say "that sucks" or say nothing..instead of "my grandpa had Parkinson's, but my grandma gave him fish oil everyday, so he had no symptoms....REALLY? No symptoms? Then he didn't have Parkinson's!	Negatif
2) On WorldParkinsonsDay discover how a clinical study led by EUfunded TreatER project is administering a promising Parkinson's drug to the first human patients.	Pozitif
3) A new test agent could lead to early diagnosis of prion diseases, Alzheimer's and Parkinson's for the first time.	Pozitif
4) 20 years ago no one would have believed that the gut was an issue in Parkinson, let alone something deserving a special issue!	Negatif
5) Chapter examines alpha-syn's activity as an antimicrobial peptide Right pointing backhand index and proposes a model for how #infectious agents, in conjunction w/ inflammatory, environmental, and genetic facilitators, may result in transfer of alpha-syn from the periphery to the brain in Parkinson's/MSA.	Nötr

Sosyal medya platformlarından her bir kullanıcıdan toplanan ham veri kümesi oldukça kirlidir. Bu nedenle, farklı ön işleme teknikleri uygulamasına ihtiyaç vardır. Bu çalışmada, bağlaçların kaldırılması (stop-word elimination), hashtaglerin kaldırılması (removing hashtags), URLlerin kaldırılması (removing URLs), ve kök bulma (stemming) teknikleri uygulanmaktadır [3].

Twitter' ın karakter kısıtlaması nedeniyle kullanıcıların duygularını yeterince ifade edemedikleri bir gerçektir. Bu sorunu gidermek için Word2Vec, GloVe ve FastText gibi yerleştirme modellerine odaklanılmıştır. Bu şekilde, her yorum kelime yerleştirme modelleri kullanılarak anlam, içerik ve söz dizimi açısından zenginleştirilmiştir. Bu yöntemlerle, Twitter' da fikirlerini ifade etmedeki sınır sorunu kullanıcı duygularını anlamak için bir sorun olmaktan çıkmıştır. Kelime yerleştirme modellerinden çıkan kelime vektörleri, derin öğrenme algoritmalarına girdi olarak verilmiştir. Bu aşamadan sonra, geleneksel makine öğrenme algoritmaları kullanmak yerine, evrişimli sinir ağları (CNN), tekrarlayan sinir ağları (RNN) ve uzun kısa süreli bellek ağları (LSTM) gibi üç farklı derin öğrenme mimarisi sınıflandırma amacıyla kullanılmaktadır. Önerilen sistemin akış şeması Şekil 1’ de verilmiştir. Şekil 1’ de yer alan ön işleme yöntemleri, kelime yerleştirme modelleri ve derin öğrenme algoritmaları için şu kısaltmalar kullanılmıştır: SWE: Bağlaçları kaldırma, RH: Hashtagleri kaldırma, RU: URL'leri kaldırma, STM: Kök bulma, AOT: Bunların hepsi, CNN: Evrişimli sinir ağı, RNN: Tekrarlayan sinir ağı, LSTM: Uzun kısa süreli hafıza ağı.

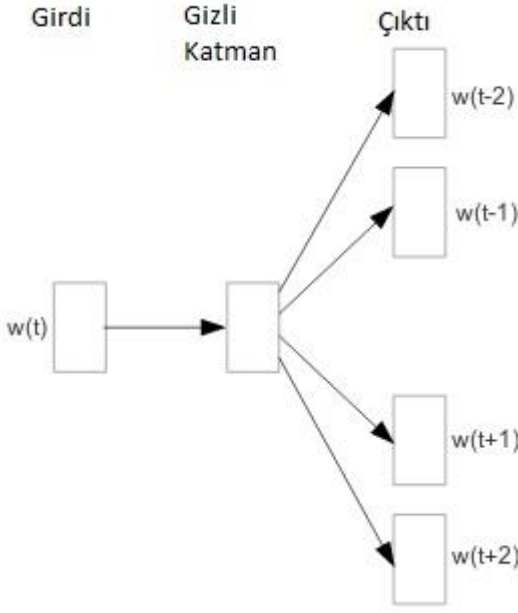


Şekil 1 : Önerilen sistemin akış şeması.

## 3.2 Kelime Yerleştirme Modelleri

### 3.2.1 Word2Vec

Word2Vec, metni işleyen iki katmanlı bir sinir ağıdır. Word2Vec derin bir sinir ağı olmasa da metni derin ağların anlayabileceği sayısal bir forma dönüştürür. Kelime vektörlerini oluştururken pencere genişliği, yerleştirme boyutu gibi hiper parametreler bulunmaktadır. Pencere genişliği hedef kelimenin sağında ve solunda kaç kelime olması gerektiğini belirtirken, yerleştirme boyutu ise her bir kelimenin kaç boyutlu vektör olarak tanımlanacağını belirtir. Bu durum gizli katmandaki nöron sayısına karşılık gelmektedir.



Şekil 2 : Skip-gram model mimarisi.

Mikolov ve arkadaşları [13],[15] Skip-gram ve Sürekli Sözcük Torbası (CBOW) modelleri olmak üzere iki farklı model önermektedir. Şekil 2' de Skip-gram modeli mimarisi verilmiştir. Skip-gram modelleri, bir cümle veya belgedeki bir kelimenin etrafındaki kelimeleri tahmin eder [12]. Girdi ve çıktıları olasılık olarak benzetip anlamsal olarak en uygun biçimde temsil etmek amaçlanır. Örneğin, 'ben bugün çok fazla çalıştım' cümlesi için, 'çok' kelimesi girdi olarak kullanılır ve pencere boyutu 5 olarak ayarlandığında, 'ben', 'bugün', 'fazla' ve 'çalıştım' kelimeleri çıktı olarak kullanılır. Matematiksel olarak ifade edildiğinde,  $w_1, w_2, w_3, \dots, w_T$  kelime dizisi aşağıdaki denklemi sağlar. Burada,  $j$  verilen bir kelime için öngörülme çalışılan komşu kelime sayısının iki katıdır ve eğitilecek bağlamın büyüklüğünü temsil etmektedir.  $J$  arttırıldığında doğruluk oranları daha yüksek vektörler elde edilmesi beklenmektedir, ancak eğitim süresi uzamaktadır. Skip-gram modelinin amacı, ortalama doküman olasılığını en üst düzeye çıkarmaktır. Bu çalışmada Skip-gram modeline odaklanılmıştır. Denklem 1, Skip-gram modelini ifade eder. Burada  $w_T$ , orta kelimeyi temsil ederken eğitim için verilen kelimeler dizisi  $w_1, w_2, w_3, \dots, w_T$  şeklindedir. Ayrıca,  $n$  daha fazla veya daha az çevreleyen kelimeleri içerecek şekilde ayarlanabilen eğitim bağlamının boyutunu belirtir.

$$J_{\theta} = \frac{1}{T} \sum_{t=1}^T \sum_{-j \leq s \leq j, s \neq 0} \log p(w_{t+s} | w_t) \quad (1)$$

### 3.2.2 GloVe

GloVe, kelime temsili için global vektörler, önerilen bir başka kelime yerleştirme modelidir. İstatistikleri kontrol etmeyen algoritmalara dayanır. Bir korpustaki kelime oluşumlarının istatistikleri, kelime temsillerini öğrenmek için tüm denetlenmemiş yöntemlerin kullanabileceği temel bilgi kaynağıdır. Kelime vektörleri bu anlamı temsil edebilir.

Skip-gram ve CBOW gibi modeller anlamsal bilgileri yakalar, ancak birlikte çalışabilirlik için istatistik kullanmazlar. Matris ayrıştırma yöntemleri bu istatistikleri kullanmasına rağmen,

anlamsal ilişkileri yakalayamazlar. Bu kelime yerleştirme modeli, problemi olasılık istatistiklerini kullanarak yeni bir amaç fonksiyonu yaratarak çözmeyi amaçlar. GloVe modeli kelime yerleştirme işlemlerini elde etmek için aşağıda yer alan Denklem 2' deki işlevi kullanır [16]. Burada,  $X$  kelime birliktelik matrisini,  $X_{ij}$  'in her elemanı  $i$  kelimesinin  $j$  bağlam kelimesinde kaç kez görüldüğünü göstermektedir.

$$J_{\theta} = \sum_{i,j=1}^v f(X_{ij})(w_i^T + b_i + \bar{b}_j - \log X_{ij})^2 \quad (2)$$

### 3.2.3 FastText

FastText, Word2Vec modelinin bir uzantısı olan başka bir kelime yerleştirme modeli yöntemidir. FastText, son birkaç on yılda doğal dil işleme ve makine öğrenen toplulukların getirdiği en başarılı konseptlerden bazılarını birleştirir. Bunlar, cümleleri kelime torbası ve n-gram torbasıyla temsil etmenin yanı sıra alt kelime bilgisini kullanma ve gizli bir temsil yoluyla sınıflar arasında bilgi paylaşımını içerir. Ayrıca hesaplamayı hızlandırmak için sınıfların dengesiz dağılımından faydalanan hierarchical softmax kullanılır. Örneğin,  $n = 3$  ile "artificial" kelimesi seçilirse, FastText aşamaları <ar, art, rti, tif, ifi, fic, ici, ial, al>, kelimenin başlangıcı ve bitişidir. Bir kelime veya harften ne kadar olduğunu anlamamızı sağlar. Çok sıklıkla geçmeyen kelimelerin n-gramlarının ortaya çıkma olasılığı zayıf olduğu için bu kelimeler daha doğru bir biçimde temsil edilir. FastText, değiştirilmiş bir Skip gram kaybı fonksiyonuna sahip Word2Vec için önerilen negatif örnekleme Skip gram modelini kullanır.  $G_w \subset \{1, \dots, G\}$  a kelimesinde görünen n-gram kümesi olsun, kelimenin puanı n-gramın vektör aşamalarının toplamıyla Denklem 3'deki FastText genel denklemi elde edilir [12]. Burada,  $w$  kelimesi, kelimenin kendisi için bir vektörden oluşan tüm n-gram  $z_g$ ' nin toplamı olarak temsil edilir. Ayrıca  $v$  ile sözlüğü,  $c$  ise gizli bir katman çıktısı bağlam kelimesi vektörünün ağırlıklı ortalamasıdır.

$$s(w, c) = \sum_{g \in G_w} z_g^T v_c \quad (3)$$

### 3.3 Derin Öğrenme Teknikleri

Bu çalışmada, Evrişimli Sinir Ağları (CNN'ler), Tekrarlayan Sinir Ağları (RNN) ve Uzun Kısa Süreli Bellek ağları (LSTM) gibi yaygın olarak kullanılan üç derin öğrenme algoritmasına odaklanıyoruz.

#### 3.3.1 Evrişimli Sinir Ağları (CNN)

Evrişimli sinir ağları (CNN'ler) bir tür çok katmanlı algılayıcıdır (MLP) [17]. İleriye dönük bir sinir ağı olan CNN, hayvanların görsel merkezinden ilham almıştır. Buradaki matematiksel evrişim süreci, bir nöronun uyarıcı alanından uyarıcılara tepkisi olarak düşünülebilir. Tüm CNN katmanları tamamen birbirine bağlanacak şekilde tasarlanmıştır ve her bir evrişim filtresi öğrenilecek özellikleri oluşturur. Bu katlamalı katmanlar, havuzlama yoluyla hem ebatta hem de eğitim süresinde optimizasyon sağlar.

Bu katmanlar;

- Evrişimsel Katman — Özellikleri belirlemek amacıyla kullanılır.
- Non-Linearity Katman — Sisteme lineer olmayanlığın (non-linearity) belirtilmesi için kullanılır.



- Pooling (Downsampling) Katman — Ağırlık sayısını düşürür ve uygunluğu kontrol eder.
- Flattening Katman — Klasik sinir ağı için verileri hazır hale getirir.
- Fully-Connected Katman — Sınıflamada işleme alınan standart sinir ağıdır.


Temel olarak, CNN, sınıflandırma probleminin çözüm yolu için standart sinir ağı kullanır ve bilgileri tespit etmek ve bazı özellik durumlarını belirlemek için diğer katmanları kullanır.

### 3.3.2 Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan sinir ağı (RNN), önceki adımdan gelen çıkışın mevcut aşamaya girdi olarak beslendiği bir tür sinir ağıdır [36]. RNN, kelimeleri hatırlama gereği nedeniyle önerilmektedir. Bu sorun gizli katman yardımı ile çözülür [14],[37]. RNN'in en önemli özelliği, bir dizi hakkında bazı bilgileri hatırlayan gizli durumdur (secret state). RNN, hesaplananlarla ilgili tüm bilgileri hatırlayan bir belleğe sahiptir. RNN, diğer sinir ağlarından farklı olarak, parametrelerin karmaşıklığını azaltır. Çıktıyı üretmek için tüm girdilerde veya gizli katmanlarda aynı görevi gerçekleştirir. Her giriş için aynı parametreleri kullanmak, parametrelerin karmaşıklığını azaltır.

### 3.3.3 Uzun Kısa Süreli Bellek Ağları (LSTM)

Uzun Kısa Süreli Bellek ağları genellikle "LSTM" olarak adlandırılır ve uzun vadeli bağımlılıkları öğrenebilen özel bir RNN türüdür. Başlangıç noktası, derin sinir ağlarını eğitirken, geri yayılım algoritmasını kullanarak üssel hata büyümesi sorununa bir çözüm sağlamaktır. Bu sorunun temel nedeni, aktivasyon fonksiyonu tarafından üretilen değerlerin sürekli olarak -1, 1 aralığında olması, böylece bu değerlerin geri yayılma algoritmasına verilmesi ve sıfır ile çarpılmasıdır. Bu problemten kaçınmak ve karmaşık yapılar için daha iyi öğrenme algoritmaları tasarlamak için geliştirilen LSTM, uzun vadeli bağımlılıkların ve uzun vadeli bilgilerin hatırlanması gereken problemlerde iyi sonuçlar vermektedir. RNN hücresine ayrıca bellek eşlik eder. Her adımda, öğrenilen hücrelerin hangilerinin atılması gerektiğine ve hangilerinin güncelleneceğine karar verilir. Nöral makine çevirisi için Google tarafından başarıyla kullanılan bir yapıdır. Bu çalışmada, daha önce kullanılan kelimelerin anlamlarını öğrenmek ve bu anlamlara dayalı tahminler üretmek için kullanılmıştır [12],[18]. Şekil 3' te LSTM ağı mimarisidir.



Şekil 3 : LSTM ağı mimarisidir.

## 4 Sonuçlar

Bu çalışmada, Parkinson hastalığı ile ilgili kullanıcı yorumlarının duygularını kelime yerleştirme modelleri ve derin öğrenme algoritmaları kullanarak analiz etmek için kapsamlı deneyler yapılmıştır. Her modelin sınıflandırma performansını ve çalışmalarımızın katkısını göstermek için deneylerde bir değerlendirme ölçütü olarak doğruluk metriği kullanılmıştır. Önceki literatür çalışmalarına benzer şekilde

[37],[38] verilerin eğitimi için veri kümesinin %80' i ve test için ise %20' si kullanılır. 100 boyutlu belgeleri göstermek için Google Haberler veri kümesinden Word2Vec Skip-gram modeli ile önceden eğitilmiş vektörler kullanılmıştır.

Bölüm 3.1' de bahsedilen ön işleme yöntemleri için SWE, RH, RU, STM ve AOT ve derin öğrenme algoritmaları için CNN, RNN ve LSTM kısaltmaları kullanılmıştır. Elde edilen en iyi doğruluk sonuçları kalın harflerle belirtilmiştir.

İlk aşamada, ön işleme yöntemlerinin kelime yerleştirme modelleri üzerindeki etkisi gösterilmiştir.

Tablo 2 : Ön işleme modellerinin kelime yerleştirme yöntemlerine göre doğruluk sonuçları.

Ön işleme modelleri	Word2Vec	GloVe	FastText
SWE	81.23	80.87	78.98
RH	83.75	81.51	80.72
RU	<b>83.94</b>	<b>82.25</b>	<b>81.86</b>
STM	78.36	76.79	75.69
AOT	82.48	80.59	78.83

Tablo 2' de, ön işleme yöntemlerinin %80 eğitim kümesinde kelime yerleştirme modelleri üzerindeki etkisi yukarıdaki gibi gösterilmiştir. RU, önerilen sistemin başarısını artırarak, %83.75 doğruluk başarısı ile rekabet eden RH'ye kıyasla %83.94 doğrulukla üstün sınıflandırma performansı sergiler. Bunu %82.48 ile AOT, %81.23 ile SWE ve %78.36 ile STM izlemektedir. Yerleştirme modelleri arasında Word2Vec, ön işleme yöntemi RU olarak ayarlandığında, sınıflandırma başarısını %83.94 doğrulukla dikkat çekici bir şekilde göstermektedir. Ayrıca, Word2Vec diğer kelime yerleştirme modellerinden daha iyi performans gösterirken, FastText kelime yerleştirme modellerinde %81.86 ile en düşük sınıflandırma performansına sahiptir. Dahası, Word2Vec, FastText'in başarısı göz önüne alındığında yaklaşık %2 oranında bir iyileşme sağlarken, GloVe FastText'in sınıflandırma performansına kıyasla yaklaşık %1 oranında bir geliştirme sağlar.

RU' nun üstün başarısına ek olarak, STM sınıflandırmadaki en kötü performansı sergilemektedir. Tablo 2' in sonucu olarak ön işleme modellerinin sınıflandırma doğruluklarının sırası genellikle şöyledir: RU> AOT> SWE> STM. Bu çalışmada RU, sınıflandırma üzerindeki başarılı etkisinden dolayı önerilen sistemin ön işleme modeli olarak seçilmiştir.

Tablo 3 : Doküman boyutuna göre Word2Vec modelinin derin öğrenme modelleriyle harmanlandığı durumdaki doğruluk sonuçları.

Doküman sayısı	CNN	RNN	LSTM
100	69.01	65.45	48.12
500	70.98	68.53	49.56
1000	70.59	69.29	50.37
2500	72.01	70.21	50.78
5000	73.39	71.87	51.89
7500	<b>75.12</b>	73.90	52.20
10000	74.15	72.54	51.68

Tablo 3' te doküman boyutuna göre Word2vec modelinin derin öğrenme modelleriyle harmanlandığı durumda derin öğrenme modellerinin sınıflandırma performansı değerlendirilmiştir. CNN, tüm doküman sayılarında en iyi performansı gösterirken, doküman sayısı 7500 değerinde %75.12 doğruluk oranı ile en iyi derin öğrenme modeli olduğu gösterilmiştir. CNN, RNN'ye kıyasla yaklaşık %2 daha iyi bir başarıya sahiptir, ancak ikisi de

birbirlerine çok yakın sınıflandırma performansları sergiler. Dahası, LSTM tüm doküman sayısı boyutlarında diğer derin öğrenme modellerine göre yaklaşık %20 daha başarısız olduğu görülüyor. Diğer doküman sayısı boyutlarında, CNN ve RNN arasındaki doğruluk farkı, %2 ile %3 arasında değişirken, CNN, doğruluk yüzdesi bakımından LSTM'ye kıyasla minimum %20, maksimum %24 artış gösterir. Tüm derin öğrenme teknikleri için en yüksek doğruluk oranı doküman sayısı 7500 boyutunda elde edilir. Özet olarak, derin öğrenme algoritmalarının sınıflandırma başarısı tüm doküman sayısı boyutlarında CNN>RNN> LSTM şeklinde sıralanır.

Önerilen hibrid modelimizin Word2Vec için Skip-gram modeli ile önceden eğitilmiş vektörlerle kullanıldığından bahsetmiştik. Skip-gram modeli yerine önerilen hibrid modelin Word2Vec' in CBOW modeliyle gerçekleşmesi durumunda, sistem performansı Tablo 3' te yer alan sonuçlarla kıyaslandığında doküman sayısının 7500 olduğu durumda CNN modeli için yaklaşık %3, RNN algoritması için yaklaşık %5, LSTM metodu için yaklaşık olarak %1 oranında bir performans kaybı gözlenmiştir. Buradan hareketle, önerilen modelde, Word2Vec kelime yerleştirme yöntemi için Skip-gram yöntemi uygulanmıştır.

Tablo 4 : Doküman boyutuna göre GloVe modelinin derin öğrenme modelleriyle harmanlandığı durumdaki doğruluk sonuçları.

Doküman sayısı	CNN	RNN	LSTM
100	62.56	68.41	46.95
500	63.21	69.48	47.12
1000	65.93	71.32	47.71
2500	67.45	72.59	49.07
5000	68.01	74.08	50.23
7500	69.13	<b>74.46</b>	51.94
10000	67.91	72.11	50.09

Tablo 4' te doküman boyutuna göre GloVe modelinin derin öğrenme modelleriyle harmanlandığı durumda derin öğrenme modellerinin sınıflandırma performansı değerlendirilmiştir. Tablo 4' te en iyi sınıflandırma doğruluğunun Tablo 3' de de olduğu gibi 7500 doküman boyutunda açıkça görülmektedir. Tüm derin öğrenme teknikleri için 7500 doküman sayısından 10000 doküman sayısına, sınıflandırma başarısında yaklaşık %2 azalma vardır. Daha düşük doküman sayılarında, sınıflandırma performansındaki düşüş, doküman sayısı 7500 ve 10000 aralığına kıyasla keskin bir şekilde gözlenir. Daha geniş bir bakış açısıyla, RNN doküman sayısı 7500' de diğerlerine kıyasla %74.46 doğrulukla üstün sınıflandırma performansı sergiler. Bunu %69.13 doğrulukla CNN ve %51.94 doğruluk sonucu ile LSTM takip eder.

Tablo 5' te doküman boyutuna göre FastText modelinin derin öğrenme modelleriyle harmanlandığı durumda derin öğrenme modellerinin sınıflandırma performansı değerlendirilmiştir. RNN, tüm doküman sayılarında en iyi performansı gösterir. Doküman sayısı 7500 iken %73.34 doğruluk oranı ile RNN' in en iyi derin öğrenme modeli olduğu gösterilmiştir. RNN, CNN'e kıyasla yaklaşık %2 daha iyi bir başarıya sahiptir, ancak ikisi de birbirlerine çok yakın sınıflandırma performansları sergiler. Ayrıca, Tablo 3' e benzer şekilde, LSTM' in tüm doküman sayısı boyutlarında diğer derin öğrenme modellerine göre yaklaşık %20 daha başarısız olduğu gözlemlenmiştir. RNN, doküman sayısı boyutu 7500 olarak ayarlandığında %73.34 doğruluk başarısı ile doküman sayısı 5,000 olarak ayarlandığında elde edilen %71.93 doğruluk sonucuna kıyasla üstün sınıflandırma performansı sergiler. Derin öğrenme algoritmalarının

sınıflandırma başarısı tüm doküman sayılarında RNN> CNN> LSTM şeklinde sıralanır.

Tablo 5 : Doküman boyutuna göre FastText modelinin derin öğrenme modelleriyle harmanlandığı durumdaki doğruluk sonuçları.

Doküman sayısı	CNN	RNN	LSTM
100	64.35	66.48	44.77
500	65.92	68.32	46.13
1000	68.63	69.04	47.75
2500	69.22	69.85	49.81
5000	70.47	71.93	50.66
7500	71.84	<b>73.34</b>	51.94
10000	70.34	71.27	50.82

Bu çalışmada, Parkinson hastalığına ilişkin son çalışmaların aksine, kullanıcıların sosyal medya platformlarındaki duyguları analiz edilerek Parkinson hastalığının tespitine odaklanıldı. Kullanıcıların, Parkinson hastalığı hakkındaki görüşlerini anlamak ve analiz etmek için kelime yerleştirme modelleri ve derin öğrenme yöntemleri harmanlanmış ve sınıflandırma amacıyla kullanılmıştır. Bu amaçla CNN, RNN ve LSTM derin öğrenme algoritmaları olarak kullanılmakta, Word2Vec, GloVe ve FastText ise kelime yerleştirme modelleri olarak değerlendirilmektedir. Dahası, önerilen modelin sınıflandırma performansını arttırmak için ön işleme yöntemleri olarak SWE, RH, RU ve STM üzerinde de duruyoruz. Ayrıca, doküman sayılarının etkisi de sınıflandırma performanslarına göre incelenmiştir. Sonuç olarak, ön işleme aşamasında CNN ile Word2Vec+RU kombinasyonunun kullanılması, kullanıcıların Parkinson hastalığına karşı duyarlılıklarını belirlemek amacıyla doküman sayısı 7500 için kayda değer bir sınıflandırma başarısı gerçekleştirir.

Bu çalışma, [39]' daki çalışmanın genişletilmiş halidir. [39]' da yazarlar derin öğrenme algoritmalarının ve kelime yerleştirme modellerinin performansını birbirinden bağımsız olarak farklı eğitim yüzdelerinde değerlendirmekteydiler. Bu çalışmamızda, eğitim yüzdesi %80 olarak ayarlanmış olup kelime yerleştirme modelleriyle derin öğrenme modelleri harmanlanmıştır. Dolayısıyla, her iki çalışmada da önerilen modeller birbirinden farklıdır. Ayrıca [39]' daki çalışmada sadece farklı eğitim yüzdelerinde ve ön işleme yöntemlerinde derin öğrenme algoritmalarının ve kelime yerleştirme modellerinin ayrı ayrı performansları incelenirken bu çalışmada, önerilen hibrid modellerin doküman sayıları üzerindeki başarısı da sunulmuştur. Dahası, bu çalışmadaki ön işleme yöntemleri sadece kelime yerleştirme modelleri üzerinden değerlendirilmiş olup [39]' daki çalışmanın kapsamı amacıyla ön işleme yöntemlerinin her modele olan ilişkisi gösterilmiştir. Önceki çalışmamızda [39], deney sonuçlarının karşılaştırılması açısından %80 eğitim verisi dikkate alındığında kelime yerleştirme modellerinden Word2Vec, %76.64 doğruluk sonucu sunmakta olup bu çalışmada, hibridlenen modellerden Word2Vec kelime yerleştirme modelinin en iyi sonucu CNN algoritmasıyla birleştirilerek ve %75.12 doğruluk sonucu sunarak elde edildiği gözlenmiştir. Aradaki fark, ön işleme yöntemlerinden sadece bir tanesinin kullanılmasından kaynaklı olabilir. Ayrıca [39]' daki çalışmadan en iyi sınıflandırma performansı sistem tek başına modellendiğinde LSTM algoritmasına ait iken bu çalışmada, hibridlenecek kelime yerleştirme modeline göre değişkenlik göstermekte olup en kötü performans, LSTM derin öğrenme algoritması ile elde edilmiştir.

Bildiğimiz kadarıyla, bu; sözcük yerleştirme modelleri ve derin öğrenme algoritmaları kullanarak Parkinson hastalığının algısını analiz eden ilk çalışmadır. Bu şekilde, kullanıcıların Parkinson hastalığına ilişkin duygu analizi, Parkinson hastaları ve yakınları için hem erken tanı hem de tedavi sürecinde yeni bir bakış açısı sağlayabilir. Ayrıca, bu çalışma, Parkinson hastalığı ile ilgili tweetlerden elde edilen analizlerin, Parkinson hastalarının bakım sürecinde nelere ihtiyaç duyduğunu ve Parkinson hastalarının ve yakınlarının sağlık sorunları hakkında birbirleriyle nasıl iletişim kurduğunu ortaya çıkaran değerli bir sağlık hizmeti kaynağı olduğunu göstermektedir. Gelecekteki bir çalışma olarak, Parkinson hastalığının erken tespitini güçlendirerek hem metin içerikli hem de sesli kayıt verilerini içeren bir hibrit modeli geliştirmeyi planlıyoruz.

## 5 Kaynaklar

- [1] Eckler P, Worsowicz G, Rayburn J. "Social media and healthcare: an overview". *PM&R*, 2(11), 1046-1050, 2010.
- [2] Prieto VM, Matos S, Alvarez M, Cacheda F, Oliveira JL. "Twitter: a good place to detect health conditions". *Public Library of Science one*, 9(1), e86191, 2014.
- [3] Sinnenberg L, Buttenheim AM, Padrez K, Mancheno C, Ungar L, Merchant RM. "Twitter as a tool for health research: a systematic review". *American Journal of Public Health*, 107(1), e1-e8, 2017.
- [4] Neiger BL, Thackeray R, Burton SH, Thackeray CR, Reese JH. "Use of Twitter Among Local Health Departments: An Analysis of Information Sharing, Engagement, and Action". *Journal Of Medical Internet Research*, 15(8), e177, 2013.
- [5] Beykikhoshk A, Arandjelović O, Phung D, Venkatesh S, Caelli T. "Data-mining Twitter and the autism spectrum disorder: a pilot study". *IEEE/ACM 2014 International Conference on Advances in Social Networks Analysis and Mining*, Beijing, China, 17-20 August 2014.
- [6] Beykikhoshk A, Arandjelović O, Phung D, Venkatesh S. "Overcoming Data Scarcity of Twitter: Using Tweets as Bootstrap with Application to Autism-Related Topic Content Analysis". *IEEE/ACM 2015 International Conference on Advances in Social Networks Analysis and Mining*, Paris, France, 25-28 August 2015.
- [7] Chew C, Eysenbach G. "Pandemics in the Age of Twitter: Content Analysis of Tweets During the 2009 H1N1 Outbreak". *Public Library of Science one*, 5(11), e14118, 2010.
- [8] De Rijk MD, Tzourio C, Breteler MM, Dartigues JF, Amaducci L, Lopez-Pousa S, Rocca WD. "Prevalence of parkinsonism and Parkinson's disease in Europe: the EUROPARKINSON Collaborative Study. European Community Concerted Action on the Epidemiology of Parkinson's disease". *Journal of Neurology, Neurosurgery & Psychiatry*, 62(1), 10-15, 1997.
- [9] Fahn S. "Description of Parkinson's Disease as a Clinical Syndrome". *Annals of the New York Academy of Sciences*, 991, 1-14, 2003.
- [10] Elman JL. "Finding structure in time". *Cognitive Science*, 14(2), 179-211, 1990.
- [11] Joulin A, Grave E, Bojanowski P, Douze M, Jégou H, Mikolov T. "Fasttext. zip: Compressing text classification models". *ICLR 2017 International Conference on Learning Representations*, Toulon, France, April 24 - 26, 2017.
- [12] Kilimci ZH, Akyokuş S. "Deep Learning-and Word Embedding-Based Heterogeneous Classifier Ensembles for Text Classification". *Complexity*, 2018, 106-116, 2018.
- [13] Le Q, Mikolov T. "Distributed representations of sentences and documents". *International conference on machine learning*, Beijing, China, 21-26 June 2014.
- [14] Lipton ZC, Berkowitz J, Elkan C. "A critical review of recurrent neural networks for sequence learning". *arXiv preprint arXiv:1506.00019*, 2015.
- [15] Mikolov T, Chen K, Corrado G, Dean J. "Efficient estimation of word representations in vector space". *International Conference on Learning Representations Workshop*, Scottsdale, Arizona, 2-4 May 2013.
- [16] Pennington J, Socher R, Manning C. "Glove: Global vectors for word representation". *In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing*. Doha, Qatar, 25-29 October 2014.
- [17] Voulodimos A, Doulamis N, Doulamis A, Protopapadakis E. "Deep learning for computer vision: A brief review". *Computational Intelligence and Neuroscience*, 130-143, 2018.
- [18] Zhang L, Wang S, Liu B. "Deep learning for sentiment analysis: A survey". *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4), e1253. 2018.
- [19] Ene M. "Neural network-based approach to discriminate healthy people from those with Parkinson's disease". *Annals of the University of Craiova-Mathematics and Computer Science Series*, 35, 112-116, 2008.
- [20] Little M, McSharry P, Hunter E, Spielman J, & Ramig. "Suitability of dysphonia measurements for telemonitoring of Parkinson's disease". *Nature Precedings*, 1-1, 2008.
- [21] Sakar CO, Kursun O. "Telediagnosis of Parkinson's disease using measurements of dysphonia". *Journal of medical systems*, 34(4), 591-599, 2010.
- [22] Das R. "A comparison of multiple classification methods for diagnosis of Parkinson disease". *Expert Systems with Applications*, 37(2), 1568-1572, 2010.
- [23] Çağlar MF, Çetişli B, Toprak İB. "Automatic recognition of Parkinson's disease from sustained phonation tests using ANN and adaptive neuro-fuzzy classifier". *Mühendislik Bilimleri ve Tasarım Dergisi*, 1(2), 59-64, 2010.
- [24] Polat K. "Classification of Parkinson's disease using feature weighting method on the basis of fuzzy C-means clustering". *International Journal of Systems Science*, 43(4), 597-609, 2012.
- [25] Luukka P. "Feature selection using fuzzy entropy measures with similarity classifier". *Expert Systems with Applications*, 38(4), 4600-4607, 2011.
- [26] Kihel BK, Benyettou M. "Parkinson's disease recognition using artificial immune system". *Journal of Software Engineering and Applications*, 4(07), 391, 2011.
- [27] Eskidere Ö. "A Comparison of Feature Selection Methods for Diagnosis of Parkinson's Disease from Vocal Measurements". *Sigma*, 30, 402-414, 2012.
- [28] Prashanth R, Roy SD. "Novel and improved stage estimation in Parkinson's disease using clinical scales and machine learning". *Neurocomputing*, 305, 78-103, 2018.
- [29] Prashanth R, & Roy SD. "Early detection of Parkinson's disease through patient questionnaire and predictive modelling". *International journal of medical informatics*, 119, 75-87, 2018.



- [30] Oscar N, Fox PA, Croucher R, Wernick R, Keune J, & Hooker K. "Machine learning, sentiment analysis, and tweets: an examination of Alzheimer's disease stigma on Twitter". *Journals of Gerontology Series B: Psychological Sciences and Social Sciences*, 72(5), 742-751, 2017.
- [31] Inan E, Soygazi F, & Mostafapour V. "TurkiS: A Turkish Sentiment Analyzer Using Domain-specific Automatic Labelled Dataset". *International Journal of Intelligent Systems and Applications in Engineering*, 7(2), 99-103, 2019.
- [32] Pervan N, Keleş Y. Derin öğrenme yaklaşımları kullanarak Türkçe metinlerden anlamsal çıkarım yapma. Yüksek Lisans Tezi, Ankara Üniversitesi, Ankara, Türkiye, 2019.
- [33] Krizhevsky A, Sutskever I, Hinton GE. "Imagenet classification with deep convolutional neural networks". *In Advances in neural information processing systems*. 1097-1105, Nevada, USA, 2-6 December 2012.
- [34] Liu P, Qiu X, Huang X. "Adversarial multi-task learning for text classification". *Association for Computational Linguistics*, Vancouver, Canada, 30 July- 4 August 2017.
- [35] Loria S. "Textblob Documentation", Brooklyn, New York, Technical Report, 2018.
- [36] Elman JL. "Finding structure in time". *Cognitive science*, 14(2), 179-211, 1990.
- [37] Kilimci ZH, Akyokuş S, Omurca SI. The effectiveness of homogenous ensemble classifiers for Turkish and English texts. *IEEE 2016 International Symposium on INnovations in Intelligent Systems and Applications*, Sinaia, Romania, 2-5 August 2016.
- [38] Schneider KM. "On word frequency information and negative evidence in Naive Bayes text classification". In *International Conference on Natural Language Processing*, Alicante, Spain, 20-22 October 2004.
- [39] Cevik F, Kilimci ZH. "Analysis of Parkinson's disease using deep learning and word embedding models". In *International Symposium on Innovative Technologies in Engineering and Science*, Şanlıurfa, Turkey, 22-24 November 2019.
- [40] Hutto CJ, Gilbert E. "Vader: A parsimonious rule-based model for sentiment analysis of social media text". In *Eighth International AAAI Conference on weblogs and social media*. May 2014.
- [41] MonkeyLearn API Reference. Available online: <https://monkeylearn.com/docs/article/api-reference/> (15.04.2020).