

Öznitelik Seçici Olarak Balina Optimizasyon Algoritması Kullanarak Türkçe Metinlerde Siber Zorbalığın Tespiti

Deniz Furkan KANBAK¹, Mümine KAYA KELEŞ^{2*}

Öz

Dünya genelinde sosyal medya kullanımının artması ile siber zorbalığın ve doğal olarak siber zorbalığa maruz kalan kişilerin sayısı da aynı oranda artmaktadır. Mağdurların daha fazla bu duruma maruz kalmaması, aynı zamanda yeni mağduriyetlerin de oluşmaması açısından siber zorbalığın tespiti önem arz etmektedir. Literatürde siber zorbalıkla ilgili birçok çalışma bulunmakta iken, Türkçe dilindeki cümleleri analiz ederek siber zorbalığı tespit eden çok fazla çalışmaya rastlanmamıştır. Bu çalışmanın mevcut çalışmalardan farkı, Türkçe hazırlanmış bir veri seti üzerinde hem önışlem yaparak siber zorbalığın tespitinin başarısını ölçmek hem de çok büyük dokümanlarla çalışıldığında öznitelik sayısını düşürerek başarıyı düşürmeyecek bir yöntem bulmaktır. Bu sebeple öznitelik seçici olarak henüz Türkçe Siber zorbalık veri setlerinde denenmemiş bir yöntem olan Balina Optimizasyon algoritması bu çalışmada kullanılmış olup veri setine önışlemler gerçekleştirilerek K-En Yakın Komşu (KNN), Çok Terimli Naive Bayes (MNB) ve Rastgele Orman (RF) sınıflandırıcı algoritmaları ile siber zorbalığın tespitinin başarısı ölçülmüştür. Yapılan deneylere göre, her üç sınıflandırıcı ile ham veri setine sınıflandırma işlemi gerçekleştirilirken hem önışlem yapıldığında hem de Balina Optimizasyon Algoritması ile öznitelik seçimi yapıldığında öznitelik sayısı azalmış olup doğruluk değeri büyük oranda artmıştır. Özellikle kök alma işlemi hariç diğer tüm önışlemlerin gerçekleştiği veri setinde sınıflandırıcı olarak RF Algoritması ile öznitelik seçici olarak Balina Optimizasyon Algoritması birlikte kullanıldığında doğruluk oranı %85'ten %91'e yükselmiştir. Bu da gösteriyor ki, önışlem yapma ve Balina Optimizasyon Algoritması ile öznitelik seçimi nitelik sayısını da önemli ölçüde azaltarak siber zorbalık tespitindeki başarıyı arttırmaktadır.

Anahtar Kelimeler: Balina Optimizasyon Algoritması, Önışlem, Öznitelik Seçme, Siber Zorbalık, Türkçe Metin.

Detection of Cyberbullying in Turkish Texts Using Whale Optimization Algorithm as Feature Selector

Abstract

With the increase in the use of social media worldwide, the number of cyberbullying and naturally the number of people who are exposed to cyberbullying is increasing at the same rate. It is important to detect cyberbullying in order not to expose the victims to this situation anymore and to prevent new victimizations. While there are many studies on cyberbullying in the literature, there are not many studies that detect cyberbullying by analyzing sentences in Turkish. The difference of this study from existing studies is to both measure the success of detecting cyberbullying by preprocessing on a data set prepared in Turkish, and to find a method that will not reduce the success by reducing the number of features when working with very large documents. For this reason, Whale Optimization algorithm, which is a method that has not yet been tried in Turkish Cyberbullying datasets as feature selector, was used in this study, and the success of detecting cyberbullying was measured with the K-Nearest Neighbor (KNN), Multinomial Naive Bayes (MNB) and Random Forest (RF) classifier algorithms by performing preprocessing on the dataset. According to the experiments, the number of features decreased and the accuracy value increased significantly when both preprocessing and feature selection were made with the Whale Optimization Algorithm, while the raw data set was classified with all three classifiers. Especially in the data set where all the other preprocessing except the stemming process took place, the accuracy rate increased from 85% to 91% when the RF Algorithm as a classifier and the Whale Optimization Algorithm as a feature selector were used together. This shows that preprocessing and feature selection with Whale Optimization Algorithm significantly reduces the number of features and increases the success in cyberbullying detection.

Keywords: Whale Optimization Algorithm, Preprocessing, Feature Selection, Cyberbullying, Turkish Text.

¹Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Yazılım Mühendisliği Bölümü, Adana, Türkiye, dfkanbak@atu.edu.tr

²Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Bilgisayar Mühendisliği Bölümü, Adana, Türkiye, mkaya@atu.edu.tr

¹<https://orcid.org/0000-0002-7125-9103>

²<https://orcid.org/0000-0001-8414-1713>

1. Giriş

Son yıllarda insanlar arasında İnternet kullanımının yaygınlaşmasıyla birlikte siber zorbalığın da hızla arttığı gözlenmektedir. Siber zorbalık, internet ve sosyal medya mesajı gibi birçok elektronik aracı kullanarak savunmasız kişilere karşı saldırgan bir tavırla bilerek gerçekleştirilen eylemler olarak tanımlanmaktadır (Çürük, 2018). Dijital 2021 Raporuna (URL-1, 2022) göre Dünyadaki internet kullanıcılarının sayısı dünya nüfusunun %59,5'ini oluşturmaktadır. Dünya nüfusuna oranla, tüm dünyadaki sosyal medya kullanıcılarının oranı %53,6 iken Türkiye'de bu oran %70,8'dir. Rakamlardan da görüldüğü üzere Türkiye'de aktif bir sosyal medya kullanıcısı bulunmaktadır. Bu sayı aynı zamanda mağduriyet yaşayabilecek potansiyel kişi sayısını da göstermektedir. Siber zorbalığın artarak devam etmesinden dolayı sosyal medya ortamındaki sanal zorbalığın tespiti de her geçen gün önemini arttırmaktadır. Sosyal medyadaki mesajların okunup siber zorbalıkların insan eliyle tespit edilmesi oldukça zor, hatta imkânsız olduğu için bunu gerçekleştirecek otomatik sistemlere ihtiyaç da giderek artmaktadır.

Bu çalışmanın amacı, metin madenciliği yöntemlerinden olan önişleme ve öznitelik çıkarımı, veri madenciliği yöntemlerinden olan sınıflandırma ve öznitelik seçiminin siber zorbalık tespiti üzerine etkilerini araştırmaktır. Bu sebeple de henüz hiçbir Türkçe siber zorbalık veri setinde öznitelik çıkarıcı olarak denenmemiş olan Balina Optimizasyon algoritmasının kullanılması sağlanarak literatüre bir yenilik katılması hedeflenmiştir.

Son yıllarda siber zorbalığın tespiti üzerine yapılan çalışmaların sayısı oldukça artmaktadır. Kontostathis ve ark. (2013), Dadvar ve ark. (2014), Hosseinmardi ve ark. (2015), Al-Mamun ve Akhter (2018), Altay ve Alataş (2018), Hussain ve ark. (2018), Sintaha ve Mostakim (2018), Çürük (2018)'nın çalışmalarında metin madenciliği yöntemleri kullanılarak siber zorbalık tespit edilmeye çalışılmıştır. Bu ilgili referansların ortak noktası İngilizce metinler üzerinde çalışılmasıdır.

Türkçe siber zorbalık veri setleri ile çalışan literatür incelendiğinde; Özel ve ark. (2017) çalışmalarında standart ön işleme teknikleri kullanarak öznitelik çıkarımı ve seçimi işlemlerini gerçekleştirmiş, farklı makine öğrenimi algoritmaları ile Türkçe sosyal medya mesajlarında sanal zorbalığı tespit etmeye çalışmışlardır.

Bozyiğit ve ark. (2018) çalışmalarında bu çalışmada da kullanılan veri setini oluşturmuş ve internet ortamında paylaşmışlardır. Ayrıca bu veri setine klasik makine öğrenmesi yöntemlerini uygulayarak Türkçe sosyal medya metinlerinde sanal zorbalığı tespit etmişlerdir. Deneysel sonuçlara göre, en başarılı algoritmaları Multimominal Naïve Bayes, Destek Vektör Makineleri ve k -En Yakın Komşu Algoritması olarak bulmuşlardır.

Yazgılı ve Baykara (2021) çalışmalarında, siber zorbalık ve türlerinin tespiti için makine öğrenmesi algoritmaları ve literatürde yapılan çalışmalar ile ilgili bilgiler sunmuşlardır.

Nergiz ve Avarođlu (2021) alıřmalarında, Twitter, Instagram ve Youtube sosyal ortamlarındaki Trke yorumlar zerinde siber zorbalık tespiti yapmıřlardır. Elde edilen sonulara gre Fasttext derin đrenme modeli ile LSTM sinir ađı kullanıldıđında %93,15 bařarı oranı ile siber zorbalıđı tespit etmiřlerdir.

Yazđılı ve Baykara (2022) bir diđer alıřmalarında Kaggle web sayfasından elde ettikleri Trke veri setini kullanarak dođal dil iřleme yntemlerini kullanarak siber zorbalıđı tespit etmiřlerdir. alıřmada Bagging, Boosting, C4.5, Gradient Boosting, K-Means, KNN, LR, NB, ANN, RO, DVM, Stokastik Gradient Descent ve XGBoost algoritmaları karřılařtırılmıř ve en iyi sonucu Lojistik Regresyon (LR) algoritması 0.8835 dođruluk oranı ile vermiřtir.

alıřmanın bir sonraki blmnde bu alıřma iin kullanılan materyal ve yntemler sunulmuřtur. nc Blmde ise bulgular ve tartıřma blm yer almaktadır. alıřma ile ilgili sonular ve neriler ise Blm 4'e eklenmiřtir.

2. Materyal ve Metot

Bu blmde alıřmada kullanılan veri seti, niřleme yntemleri, sınıflandırıcılar ve znetelik seici anlatılmıřtır.

2.1. Veri Seti

alıřma kapsamında kullanılan veri seti Twitter'dan toplanmıř 1503 tanesi siber zorbalık ieren (pozitif etiketli), 1498 tanesi de siber zorbalık iermeyen (negatif etiketli) 3001 adet Trke rneklemden oluřmaktadır. İeriđi itibariyle homojen dađılıma sahip bir metin veri setidir. İlgili veri setine Github web sitesinden (URL-2, 2022) ulařılmıřtır. Ancak literatr tarandıđında bu veri setini Bozyiđit ve ark.'nın (2018) oluřturduđu sonucuna varılmıřtır.

2.2. niřleme

Verilerin kalitesi ve ondan tretilebilecek faydalı bilgiler, modelin đrenme yeteneđini dođrudan etkilediđinden, veri n iřleme, Makine đreniminde nemli bir adımdır. alıřmada kullanılan veri setinde bazı n iřleme adımları uygulanmıřtır. İlk olarak veri setindeki kk/byk harf dnřmleri gerekleřtirilmiřtir. Daha sonra noktalama iřaretleri ve nmerik karakterler kaldırılmıřtır. Sonra stopwords denilen gereksiz kelimeler veri setinden ıkarılmıřtır. Stopwords szckleri, Metin Madenciliđi ve Dođal Dil İřleme'de yaygın olarak kullanılan ve ok az yararlı bilgi tařıyan szckleri ortadan kaldırmak iin yaygın olarak kullanılmaktadır. niřleme ařamasının en

sonunda Turkish Stemmer (URL-3, 2022) adlı kök alma metodu ile kök alma işlemi gerçekleştirilmiştir. Böylece önişlem yöntemleri ile tüm karakterleri küçük/büyük harfe dönüştürerek; noktalama işaretleri, nümerik karakterleri ve stopwords sözcükleri kaldırarak; kelime köklerini alarak verilerin yararsız bölümlerinden veya gürültüden kurtarılması sağlanmaktadır.

Çalışmadaki veri seti “Siber zorbalık içeriyor” ve “Siber zorbalık içermiyor” şeklinde 2 sınıf olarak etiketlenmiştir. Bir kelimenin bir derlemdeki belge için ne kadar önemli olduğunu yansıtmayı amaçlayan sayısal bir istatistik olan Terim Frekansı ve Ters Terim Frekansı (TF-IDF) (Rajaraman ve Ullman, 2011) kullanılarak bir matris oluşturulmuş ve öznitelikler çıkarılarak terimlerin ağırlıkları hesaplanmıştır. TF, bir belgedeki bir kelimenin terim sıklığı iken; IDF, bir dizi belgede kelimenin ters belge frekansıdır. TF-IDF (terim frekansı-ters belge frekansı) ise, bir belge koleksiyonundaki bir kelimenin bir belgeyle ne kadar alakalı olduğunu değerlendiren istatistiksel bir ölçüdür. Bu hesaplama sonucu ham haldeki veri setinden 11510 adet öznitelik çıkarılmıştır. Önişleme aşamalarının tamamı uygulandıktan sonra öznitelik sayısı 7700’e düşmüştür.

2.3. Kullanılan Sınıflandırıcılar

Çalışmada denetimli sınıflandırıcılardan k-En Yakın Komşu Algoritması (KNN), Multinomial Naïve Bayes Algoritması ve Rastgele Orman Algoritması kullanılmıştır.

2.3.1. K-En Yakın Komşu Algoritması (K-Nearest Neighbors Algoritması - KNN)

K-En Yakın Komşu Algoritması (KNN), n boyutlu uzayda en yakın k eğitim kümesini bilinmeyen küme aralarına uygulayan ve en yakın k değerlerini mesafe ölçümleri kullanarak hesaplayan bir makine öğrenme algoritmasıdır. KNN algoritması sınıflandırma işlemi için sadece eğitim setini alır (Taunk ve ark., 2019). Başka parametreye ihtiyacı yoktur. K 'nin değerinin ne olduğu fark etmeksizin model geliştirilebilir. K değerinin belirlenmesi ile sınıflandırılacak verinin sınıfı oluşturulan modelden belirlenir. KNN algoritması sınıflandırma işlemi gerçekleştirirken öncelikle Öklid, kosinüs vb. gibi mesafe ölçme metriklerini kullanarak eğitim ve test veri setleri arasında uzaklık hesaplaması yapar. Ardından K değeri ile en yakın K tane uzaklığın sınıflarının çoğunluğuna bakarak, yeni atanacak sınıfı belirler. Metin verilerinin KNN ile sınıflandırılabilmesi için önceki bölümlerde bahsettiğimiz gibi belge TF-IDF vektörüne dönüştürülmüştür. Belgeler arasındaki uzaklığın hesaplanması için kullanılan Öklid uzaklığı formülü Denklem 1’de verilmiştir.

$$uzaklık(u_i, u_t) = \sqrt{\sum_{j=1}^n (u_{i,j} - u_{t,j})^2} \quad (1)$$

u_i , i 'nci test dökümanını ifade eder. $u_{i,j}$, i 'nci test dökümanındaki k kelimesini ifade eder. $u_{t,j}$, j 'nci eğitim dökümanını ifade eder. u_t ise eğitim dökümanını ifade eder. Son olarak N , vektörün uzunluğudur.

2.3.2. Multinomial Naïve Bayes Algoritması (Çok Terimli Naïve Bayes – MNB Algoritması)

Naïve Bayes algoritması (Ren ve ark., 2009) sağlık, mühendislik ve işletme gibi birçok alanda literatürde uygulanmış ve verimli sonuçlar vermiş, olasılık tabanlı makine öğrenmesi algoritmalarından biridir. Veri setindeki her özniteliğin birbirinden bağımsız olduğunu varsayarak, her birinin hangi sınıfa ait olduğunu gösterme olasılığını hesaplar ve temel olarak Bayes teoremine dayanır. Bu çalışmada Naïve Bayes algoritmasının metin sınıflandırmasında sıklıkla tercih edilen Multinomial Naïve Bayes (MNB) sınıflandırıcısını kullanıyoruz. MNB, $c \in C$ şeklinde c kategorisine ait verilen her belge (veya metin ya da cümle) için bir olasılık hesaplar. MNB modelinin kullandığı öznitelikler, belgede bulunan kelimelerin sıklığıdır. Kelimelerin sırası ve konumu dikkate alınmaz. Dokümandaki kelimelerin sıklığına göre bir olasılık hesabı yapılır ve $P(c|d_i)$ olasılığı en yüksek olan sınıfa atanır. MNB'nin formülü Denklem 2'de verilmiştir.

$$P(c|d_i) = \frac{P(c) P(d_i|c)}{P(d_i)}, \quad (2)$$

$P(c|d_i)$, d_i dokümanının c sınıfına ait olma olasılığını ifade eder. $P(c)$ ise Denklem 3'teki gibi formüle edilebilir.

$$P(c) = \frac{c \text{ kategorisine ait dökümanların sayısı}}{\text{toplam döküman sayısı}}, \quad (3)$$

$P(d_i|c)$, d_i dokümanının c sınıfında bulunma olasılığını ifade eder. Formülü Denklem 4'te verilmiştir.

$$P(d_i|c) = \left(\sum_n \text{sayaç}_{ni} \right) \prod_n \frac{P(w_n|c)^{\text{sayaç}_{ni}}}{\text{sayaç}_{ni}!} \quad (4)$$

sayaç_{ni} ise n kelimesinin d_i dokümanı içerisindeki frekansını ifade eder.

2.3.3. Rastgele Karar Ormanları Algoritması (Random Forest Algoritması – RF)

Breiman ve ark.'nın (2001) çalışmalarına göre rastgele karar ormanları olarak da bilinen rastgele orman algoritması, sınıflandırma ve regresyon sorunlarını çözmek için kullanılan bir topluluk öğrenme tekniğidir. Karar ormanı topluluğu, çok sayıda üretilen çok sayıda sınıflandırma ve regresyon karar ağaçlarından oluşur. Rastgele Orman, sınıflandırma ve regresyon ağacının (CART) her bir düğümünde rastgele alt öznitelik uzayı üreterek, rastgele alt uzay yöntemlerini (RSM) torbalama metodu ile birleştirir (Qiu ve ark., 2017). Rastgele alt uzay yöntemi orijinal girdi uzayının rastgele seçilmiş alt uzayları üzerinde öğrenen makinelerin eğitildiği birleşik bir stratejidir. Sonuçlar, medyan değerlerine veya oy çoğunluğuna göre birleştirilir. Karar ağacının her bir düğümünde, toplam n adet girdi özniteliğinden m adet özellik rastgele seçilir. Üstün doğruluğu ve aykırı değerlere ve kirli veriye karşı iyi olmasının yanı sıra, rastgele orman algoritmasının en kullanışlı özelliklerinden biri çok sayıda dahili teşhis göstergesini hesaplama kapasitesidir. Tahmin işlemi, orman oluşturma kararı aşamasında toplanan veriler kullanılarak gerçekleştirilir (Karasu ve ark., 2019). Rastgele orman metodolojisinin rastgele örnekleme ve topluluk yöntemlerinde bulunan prosedürlerin gelişmiş yönlerini entegre etmesi nedeniyle, daha geniş genellemeler ve daha güvenilir tahminler sağlar.

2.4. Öznitelik Seçimi

Öznitelik seçimi, model yapımında kullanılacak en tutarlı ve ilgili özellikleri ayırma işlemidir. Öznitelik seçme teknikleri, gereksiz veya alakasız özellikleri ortadan kaldırarak ve öznitelik kümesini en alakalı olanlara makine öğrenimi modeliyle daraltarak girdi değişkenlerinin sayısını azaltmak için kullanılmaktadır. Öznitelik seçim algoritmaları, etiketli veriler için kullanılabilen denetimli veya etiketlenmemiş veriler için kullanılabilen denetimsiz olarak kategorize edilebilmektedir. Denetimsiz teknikler, filtre yöntemleri, sarma yöntemleri, gömülü yöntemler veya hibrit yöntemler olarak sınıflandırılmaktadır.


Ortalama veri kümesinin boyutu ve karmaşıklığı katlanarak artmaya devam ettikçe, öznitelik seçimi giderek daha önemli hale gelmektedir. Bu sebeple bu çalışmada öznitelik sayısını azaltırken başarıyı da düşürmeyecek bir yöntem bulunması amaçlanmıştır. Son dönemlerde doğadan esinlemeli algoritmaların öznitelik seçici olarak kullanıldığı ve başarılı olduğu görülmektedir. Bu nedenle bu çalışmada henüz hiçbir Türkçe siber zorbalık veri setinde öznitelik seçici olarak kullanılmamış bir doğadan esinlemeli algoritma olan Balina Optimizasyon Algoritması tercih edilmiştir.

2.4.1. Öznitelik Seçici Olarak Balina Optimizasyon Algoritması

Balinalar dünya üzerindeki en büyük memeliler olarak bilinirler. Yetişkin bir balina 180 ton ağırlığına ve 30 metre uzunluğa ulaşabilir. Dişilerinin boyutu erkeklerinin boyutundan çoğu zaman daha büyüktür ve bu özelliğe sahip nadir memelilerdendir. Genel olarak balina olarak adlandırılırsalar da kendi içerilerinde farklı türlere ayrılırlar. Balinalar çoğu zaman yırtıcı olarak bilinirler. Okyanusların yüzeyinde nefes almak zorunda oldukları için balinalar hiçbir zaman tam olarak uyumazlar. İhtiyaç olduğu durumlarda beyinlerinin sadece yarısı uyur. Balinalar, duyguları olan, oldukça akıllı canlılardır.

Hof ve ark. (2007), balinaların beyinlerinin belli bölgelerinde insanlarınkine benzer bazı hücreler bulunduğunu ve bu hücrelere iş hücre dendiğini ortaya koymuştur. Bu hücreler insanlarda karar vermeden, duygulardan ve sosyal davranışlardan sorumludur. Bu nedenle, iş hücrelerimiz bizi diğer canlılardan ayıran farklardan biridir. Balinalarda ise iş hücre sayısı, insanlarda bulunanın iki katı kadardır ve akıllı olmalarının ana kaynağı da budur. Balinaların (özellikle katil balinaların) kendi aralarında iletişim kurabilecekleri bir diyalekt geliştirdikleri de gözlemlenmiştir.

Balinaların sosyal davranışları ilgi çekicidir. Çoğu zaman sürü şeklinde yaşasalar da tek olarak da yaşayabilirler. En büyük balina türlerinden biri kambur balinalardır (*Megaptera novaeangliae*). Kambur balinalar çoğunlukla krillerle ve sürü halindeki küçük balıklarla beslenirler. Kambur balinaların en ilginç özelliğe ise gösterdikleri avlanma davranışlarıdır. Kambur balinaların avladığı sürüler genellikle yüzeye yakın yerlerde bulunurlar. Kambur balinalar ise yüzeye çok uzak olmayan bölgelerden soluk vererek kabarcıklar meydana getirirler. Dairesel şekilde hareket ederek ve soluk vermeye düzenli periyodlarla devam ederek yüzeye yakın yerlerdeki balık sürülerini çıkardıkları baloncuk ağına sıkıştırırlar. Dairesel hareketlerinin çapını yavaşça azaltarak yüzeye doğru hareket ederler. Avlarını sıkıştırmak için yaptıkları harekete kabarcık ağı (bubble-net) denir. Şekil 1 kabarcık ağı hareketini temsil eden bir görseldir. Mirjalili ve ark. (2016) kabarcık ağı hareketini matematiksel olarak modellemişlerdir ve optimizasyon algoritması olarak farklı mühendislik problemlerinde kullanmışlardır. Balina Optimizasyon Algoritması modellenirken 3 parçaya ayrılmıştır; avın etrafını sarma, ava doğru hareket etme ve av arama.



Şekil 1. Kabarcık ağı hareketi (Mirjalili ve ark., 2016).

2.4.1.1 Avın Etrafını Sarma

Optimizasyon algoritmalarının genelinde ulaşılmaması gereken nokta optimum çözüm olarak değerlendirilir. Her zaman ulaşılmaması gereken noktaya ulaşılamasa da, bu noktanın yakınındaki bir nokta optimum çözüm olarak kabul edilebilir. Her bir iterasyonda en iyi konumdaki çözüm belirlendikten sonra bir sonraki iterasyon bu çözümün etrafında oluşur. Balina Optimizasyon Algoritmasında ise ulaşılmaması gereken nokta avdır. Her iterasyonda av en çok yaklaşan çözüm için diğer çözümlerin konumlarında güncelleme yapılır. Denklem 1 ve Denklem 2’de avın etrafını sarma davranışının matematiksel modeli gösterilmiştir.

$$\vec{D} = |\vec{C} \cdot \vec{X}^*(t) - \vec{X}(t)| \quad (1)$$

$$\vec{X}(t+1) = |\vec{X}^*(t) - \vec{A} \cdot \vec{D}| \quad (2)$$

t , o anda bulunan iterasyonu, A ve C katsayı vektörlerini, X^* en iyi çözüm vektörünü ifade etmektedir.

2.4.1.2 Ava Doğru Hareket Etme

Ava doğru hareket etme davranışı baloncuk çıkartma eyleminden sonraki kısmı kapsar. Bu harekette balinaların oluşturduğu çemberi daraltması ve spiral olarak hareket etmesini ifade eder. Çemberi daraltma davranışı Denklem 3 ve 4’te modellenmiştir. Spiral hareket ise Denklem 5’te

belirtildiği şekilde modellenmiştir. Çemberi daraltma davranışı Denklem 3'teki a 'nın değerini azaltarak meydana gelir.

$$\vec{A} = 2\vec{a} \cdot \vec{r} - \vec{a} \quad (3)$$

$$\vec{C} = 2 \cdot \vec{r} \quad (4)$$


Şekil 2'de spiral hareket ve en iyi çözümün konumu gösterilmiştir. Spiral hareket davranışı için hedef konum ve çözüm adayı arasındaki mesafe hesaplanarak Denklem 5 oluşturulmuştur.

$$\vec{X}(t+1) = \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(t) \quad (5)$$

$$\vec{D}' = \vec{X}^*(t) - \vec{X}(t)$$

Denklem 5'teki b değeri logaritmik spiral sabitini, l değeri ise $[-1,1]$ aralığındaki rastgele bir sayıyı ifade etmektedir. Balina Optimizasyon Algoritması spiral hareket ile doğrusal hareketin hangisinin yapılacağını %50 olasılıkla belirler. Denklem 6'da bu seçim modellenmiştir. Denklem 6'daki p değeri $[0,1]$ aralığında rastgele bir sayıdır.

$$\vec{X}(t+1) = \begin{cases} \vec{X}^*(t) - \vec{A} \cdot \vec{D}, & p < 0,5 \\ \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(t), & p \geq 0,5 \end{cases} \quad (6)$$



Şekil 2. Spiral Hareket (Mirjalili ve ark., 2016).

2.4.1.3 Av Arama

Kambur balinalar sürüsündeki diğer balinalara bakarak rastgele bir arama hareketi içerisinde olabilirler. Global çözüm için, çözüm adaylarının yeni konumları belirlenirken bazı durumlarda bilinen en iyi nokta yerine, rastgele belirlenen bir çözüm adayı seçilir. Bu çözüm adayının etrafında ise oluşturulacak diğer çözüm adayları oluşur. Bu yüzden A vektörünün 1'den büyük ya da -1'den küçük olacağı değerler kullanılır. Bu durumlarda çözüm adayı referans adaydan uzaklaşır. Bu davranışın modellenmesi Denklem 7 ve 8'de verilmiştir. Denklemlerdeki X_{rand} vektörü, rastgele seçilen bir çözüm vektörünü ifade eder.

$$\vec{D}' = \vec{C} \cdot \overrightarrow{X_{rand}} - \vec{X} \quad (7)$$

$$\vec{X}(t + 1) = \overrightarrow{X_{rand}} - \vec{A} \cdot \vec{D} \quad (8)$$

Denklem 8'deki A vektörünün değeri aramaların hangi ölçekte yapılacağına karar verilmesinde kullanılır. A değerinin -1'den küçük ya da 1'den büyük olduğu durumlar global arama olarak kabul edilir ve bahsedilen denklemler kullanılır. Diğer durumlarda ise yerel arama yapılır.

2.5. Değerlendirme Kriteri

Önişlem öncesi ve sonrası olmak üzere hazırlanan veri setlerinin başarısını hesaplamak için bir değerlendirme kriterine ihtiyaç bulunmaktadır. Hem uygulanan sınıflandırıcıların performansını hem de öznelik seçici olarak uygulanan Balina Optimizasyon Algoritmasının başarısını ölçmek amacıyla bu çalışmada değerlendirme yöntemleri arasında en yaygın olarak kullanılan Doğruluk (Accuracy) kriteri hesaplamalarda tercih edilmiştir. Bir sınıflandırıcının doğruluğu, toplam örnek sayısına bölünen toplam doğru tahminlerin yüzdesi olarak verilmektedir. Tanımı verilen Doğruluk değerlendirme kriterinin formülü Denklem 9'da verilmektedir. Formülde bahsi geçen terimlerin ikili sınıflandırıcı için örnek bir karışıklık matrisindeki (Stehman, 1997) durumları ise Şekil 3'te verilmektedir.

$$Doğruluk = \frac{TP+TN}{TP+TN+FP+FN} \quad (9)$$

	Tahmini Değer: POZİTİF	Tahmini Değer: NEGATİF
Gerçek Değer: POZİTİF	TP (Gerçek Pozitifler)	FN (Yanlış Negatifler)
Gerçek Değer: NEGATİF	FP (Yanlış Pozitifler)	TN (Gerçek Negatifler)

Şekil 3. İkili Sınıflandırıcı İçin Örnek Karışıklık Matrisi.

Doğruluk değeri tüm doğru cevapların (TP ve TN), tüm cevaplara (TP, TN, FP, FN) olan oranıdır. Matematiksel olarak, sınıflandırıcının doğruluğu kabul edilebilir olarak düşünülürse, sınıf etiketinin bilinmediği gelecekteki veri gruplarını sınıflandırmak için sınıflandırıcı kullanılabilir. Veri seti dengeli dağılıma sahip olduğu zaman daha başarılı sonuç üretmektedir, bu yüzden daha çok dengeli veri setleri kullanılacağı zaman tercih edilmektedir. Bu çalışmada da tercih edilme sebebi kullanılan veri setinin homojen yapıya sahip olması yani sınıflar arasındaki dağılımın yakın olmasıdır.

3. Bulgular ve Tartışma

Bu çalışmada siber zorbalığı tespit etmek için 3001 adet Türkçe siber zorbalık metni içeren veri seti üzerinde çeşitli ön işleme işlemleri sonrası KNN, Rastgeler Orman ve Çok Terimli Naive Bayes algoritmaları gibi farklı sınıflandırıcılar yardımıyla doğadan esinlemeli bir optimizasyon algoritması olan Balina Optimizasyon Algoritması öznitelik seçici olarak uygulanmıştır. KNN algoritmasının k değeri literatürdeki diğer çalışmaları da göz önünde bulundurarak 5 olarak seçilmiştir (Prabhakar ve ark., 2019). Veri seti %70 eğitim, %30 test olarak ayrılmıştır. Değerlendirme kriteri olarak Doğruluk değeri kullanılmış olup ön işlem yöntemlerine göre alınan sonuçlar Tablo 1, 2 ve 3’de gösterilmektedir. Doğruluk değerleri virgülden sonra 2 basamak olacak şekilde yuvarlanmıştır.

Tablo 1. Raw Haldeki Veri Setinden Alınan Sonuçlar.

Kullanılan Algoritma	Öznitelik Seçimi İşlemi Öncesi		Öznitelik Seçimi İşlemi Sonrası	
	Öznitelik Sayısı	Doğruluk Değeri	Öznitelik Sayısı	Doğruluk Değeri
MNB	11510	%86	11255	%88
KNN	11510	%74	9829	%72
RF	11510	%85	11011	%86

Tablo 1’den de görüldüğü üzere raw yani hiçbir işlem yapılmamış saf haldeki veri setine herhangi bir öznitelik seçimi uygulanmadığında en başarılı algoritma MNB olurken, öznitelik seçimi sonrası öznitelik sayısı düşerken başarı oranı 0.88’e yükselmektedir. En düşük öznitelik sayısını ise KNN algoritması verirken en kötü sonucu da yine KNN algoritmasının verdiği görülmektedir. Bu da

öznitelik sayısının çok fazla düşmesinin iyi bir sonuç üreteceği anlamına gelmediğini kanıtlamaktadır.

Tablo 2. Tüm önışlemlerin Uygulandığı Haldeki Veri Setinden Alınan Sonuçlar.

Kullanılan Algoritma	Öznitelik Seçimi İşlemi Öncesi		Öznitelik Seçimi İşlemi Sonrası	
	Öznitelik Sayısı	Doğruluk Değeri	Öznitelik Sayısı	Doğruluk Değeri
MNB	7700	%86	7680	%86
KNN	7700	%73	7660	%75
RF	7700	%86	7691	%86

Tablo 2’den görüldüğü üzere ise tüm önışlemlerin uygulandığı haldeki veri setine herhangi bir öznitelik seçimi uygulanmadığında en başarılı algoritmalar MNB ve RF olurken, öznitelik seçimi sonrası öznitelik sayısı düşerken başarı oranı 0.86’da kalmıştır. En düşük öznitelik sayısını ise ham haldeki veri setinde olduğu gibi KNN algoritması verirken en kötü sonucu da yine KNN algoritmasının verdiği görülmektedir. Bu da öznitelik sayısının çok fazla düşmesinin iyi bir sonuç üreteceği anlamına gelmediğini bir kez daha kanıtlarken aynı zamanda önışlemlerin hepsinin birden uygulanmasının da başarıyı yükseltmediğini göstermektedir.

Tablo 3. Kök Alma Hariç Tüm Önışlemlerin Uygulandığı Haldeki Veri Setinden Alınan Sonuçlar.

Kullanılan Algoritma	Öznitelik Seçimi İşlemi Öncesi		Öznitelik Seçimi İşlemi Sonrası	
	Öznitelik Sayısı	Doğruluk Değeri	Öznitelik Sayısı	Doğruluk Değeri
MNB	11459	%87	11161	%87
KNN	11459	%77	11415	%77
RF	11459	%87	10934	%91

Son olarak Tablo 3’ten görüldüğü üzere ise kök alma hariç tüm önışlemlerin uygulandığı haldeki veri setine herhangi bir öznitelik seçimi uygulanmadığında en başarılı algoritmalar yine MNB ve RF olurken, öznitelik seçimi sonrası öznitelik sayısı düşerken başarı oranı da RF algoritması ile sınıflandırma gerçekleştiğinde 0.91’e çıkmaktadır. En düşük öznitelik sayısını ise bu sefer RF algoritmasının verdiği görülmektedir. Bu da öznitelik sayısının hem düştüğü hem de doğruluk başarısının yükseldiği tek algoritmanın RF olduğunu göstermektedir. Kök alma hariç diğer önışlemlerin uygulanmasının da başarıyı yükselttiği gözükmemektedir. Buna Türkçe’nin gramer yapısı gereği sondan eklemeli bir dil olması sebep olmaktadır. Hali hazırda çok etkin çalışan bir kök alma aracı olmadığı için başarı oranının düştüğü literatürdeki birçok çalışmada da görülmektedir (Yazgılı ve Baykara, 2022). Bu doğrultuda, MNB ve RF sınıflandırıcılarının tahmin etme başarısı açısından, Balina Optimizasyon algoritmasının da ilgili öznitelikleri seçme açısından Türkçe metinlerdeki siber zorbalık tespiti için en uygun yöntemler olduğu sonucuna varılmıştır.

4. Sonular ve neriler

Bu alıřmada Trke hazır bir veri seti kullanılarak siber zorbalık tespiti gerekleřtirilmiřtir. alıřmanın amacını veri n iřlemlerinin siber zorbalıęa etkisi ve znitelik seimi yntemi ile boyut azaltıldıęında bařarının azalmaması oluřturmaktadır. Bu sebeple Trke siber zorbalık metinsel verilerde ilk defa bu alıřmada kullanılan Balina Optimizasyon Algoritması ile znitelik seimi iřlemi gerekleřtirilmiřtir. Veri seti zerinde doęal dil iřleme yntemleri kullanılarak gerekleřtirilen veri n iřlemlerinden sonra veri seti zerinde alıřtırılan sınıflandırma algoritmalarının performansları incelendięinde %91 doęruluk oranı ile RF sınıflandırma algoritmasının en yksek bařarı oranına sahip olduęu tespit edilmiřtir.

Yapılan deneysel alıřmalara gre en az znitelik genellikle KNN sınıflandırıcı kullanıldıęında oluřurken, en dřk doęruluk bařarısı da yine KNN sınıflandırıcı alıřtırıldıęında elde edilmektedir. niřlemin hem znitelik sayısı aısından hem de doęruluk deęerlendirme kriteri aısından nemli olduęu Bulgular Blmnde verilen  tablodan da izlenmektedir. Bu tablolara gre kk alma iřleminin Trke dilinin yapısından dolayı bařarıyı dřrdę gzlenmiřtir. En iyi sonucu kk alma iřlemi olmadan dięer tm niřlemler uygulandıęında RF sınıflandırıcısının verdięi gzlenmiřtir. Balina Optimizasyon Algoritmasının znitelik seici olarak kullanıldıęı durumlarda ise doęruluk bařarısını arttırdıęı, RF sınıflandırıcısı kullanılarak doęruluk oranı hesaplandıęında ham veri setindeki %85 olan bařarıyı zellikle yine kk alma iřlemi olmadan dięer tm niřlemler uygulandıęında %87'den %91'e ykselttięi sonucuna varılmıřtır.

Bu alıřmada literatrdeki Trke siber zorbalık veri setinin yetersizlięi grlmř ve gelecek alıřmalarda bir veri seti oluřturulması planlanmıřtır. Ayrıca kk almanın performans zerindeki etkisinin de artacaęı yntemler arařtırılacaktır. Bylece siber zorbalık tespitinde niřlem ařamalarının performansı ve bařarıyı arttıracaaęı dřnlmektedir.

Yazarların Katkısı

Tm yazarlar alıřmaya eřit katkıda bulunmuřtur.

ıkar atıřması Beyanı

Yazarlar arasında herhangi bir ıkar atıřması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Al-Mamun, A., ve Akhter, S. (2018, Aralık). Social Media Bullying Detection Using Machine Learning On Bangla Text. *10th International Conference on Electrical and Computer Engineering* (pp. 20-22). Dhaka, Bangladesh.
- Altay, E. V., ve Alataş, B. (2018, Aralık). Detection of Cyberbullying in Social Networks Using Machine Learning Methods. *International Congress on Big Data, Deep Learning and Fighting Cyber Terrorism*, Ankara, Turkey.
- Bozyiğit, A., Utku, S., ve Nasiboğlu, E. (2018). Sanal zorbalık içeren sosyal medya mesajlarının tespiti. *In 3rd International Conference on Computer Sciences and Engineering UBMK*. Sarajevo, Bosnia and Herzegovina.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Canayaz, M., ve Demir, M. (2017, Eylül). Feature selection with the whale optimization algorithm and artificial neural network. *In 2017 International Artificial Intelligence and Data Processing Symposium (IDAP)* (s. 1-5). Malatya, Türkiye: İnönü Üniversitesi.
- Çürük, E. (2018). *Sosyal Ağlardaki Siber Zorbalığın Yapay Zeka Algoritmaları İle Tespiti Ve Sınıflandırılması*. Yüksek Lisans Tezi, Mersin Üniversitesi, Fen Bilimleri Enstitüsü, Mersin.
- Dadvar, M., Trieschnigg, D., ve de Jong, F. (2014). Experts and Machines against Bullies: A Hybrid Approach to Detect Cyberbullies. *In: Advances in Artificial Intelligence* (pp. 275–281). Canada.
- Hof, P. R., ve Van der Gucht, E. (2007). Structure of the cerebral cortex of the humpback whale, *Megaptera novaeangliae* (Cetacea, Mysticeti, Balaenopteridae). *The Anatomical Record: Advances in Integrative Anatomy and Evolutionary Biology: Advances in Integrative Anatomy and Evolutionary Biology*, 290(1), 1-31.
- Hosseinmardi, H., Mattson, S. A., Ibn Rafiq, R., Han, R., Lv, Q., ve Mishra, S. (2015). Detection of cyberbullying incidents on the Instagram social network. *arXiv: 1503.03909v1 [cs.SI]*. Retrieved from <https://arxiv.org/abs/1503.03909>.
- Hussain, M. G., Mahmud, T. A., ve Akthar, W. (2018). An Approach to Detect Abusive Bangla Text. *2018 International Conference on Innovation in Engineering and Technology (ICIET)* (pp. 27-29). Dhaka, Bangladesh.
- Karasu, S., ve Altan, A. (2019, Kasım). Recognition model for solar radiation time series based on random forest with feature selection approach. *2019 11th International Conference on Electrical and Electronics Engineering (ELECO)*. Bursa, Türkiye.
- Kontostathis, A., Reynolds, K., Garron, A., ve Edwards, L. (2013). Detecting cyberbullying: Query terms and techniques. *Proceedings of the 5th Annual ACM Web Science Conference* (pp.195–204). New York, NY, USA.
- Mirjalili, S., ve Lewis, A. (2016). The whale optimization algorithm. *Advances in engineering software*, 95, 51-67.
- Özel, S. A., Saraç, E., Akdemir, S., ve Aksu, H. (2017). Detection of cyberbullying on social media messages in Turkish. *2017 International Conference on Computer Science and Engineering (UBMK)* (pp. 366–370). Antalya, Turkey.
- Prabhakar, E., Santhosh, M., Krishnan, A. H., Kumar, T., ve Sudhakar, R. (2019). Sentiment analysis of US airline twitter data using new adaboost approach. *International Journal of Engineering Research & Technology (IJERT)*, 7(1), 1-6.
- Qiu, X., Zhang, L., Nagaratnam Suganthan, P., ve Amaratunga, G. A. (2017). Oblique random forest ensemble via least Square estimation for time series forecasting. *Information Sciences*, 420, 249-262.
- Ren, J., Lee, S. D., Chen, X., Kao, B., Cheng, R., ve Cheung, D. (2009). Naive Bayes classification of uncertain data. *2009 Ninth IEEE International Conference on Data Mining*. Miami, Florida.
- Sintaha, M., ve Mostakim, M. (2018, Aralık). An Empirical Study and Analysis of the Machine Learning Algorithms Used in Detecting Cyberbullying in Social Media. *21st International Conference of Computer and Information Technology (ICCIT)*. Dhaka, Bangladesh: United International University.

- Stehman, Stephen V. (1997). Selecting and interpreting measures of thematic classification accuracy. *Remote Sensing of Environment*. 62(1), 77–89.
- Taunk, K., De, S., Verma, S., ve Swetapadma, A. (2019). A brief review of nearest neighbor algorithm for learning and classification. *2019 International Conference on Intelligent Computing and Control Systems (ICCS)*. Secunderabad , India.
- URL-1: <https://recrodigital.com/dijital-2021-raporunda-turkiye-ve-dunyada-internet-ve-sosyal-medya-kullanimi-karsilastirmasi-ocak-2021/>, (Eriřim Tarihi: 1 Nisan 2022).
- URL-2: <https://github.com/gulsan-celep/Siber-Zorbalik-ile-Model-Egitimi>, (Eriřim Tarihi: 1 Nisan 2022).
- URL-3: <https://github.com/otuncelli/turkish-stemmer-python>, (Eriřim Tarihi: 1 Nisan 2022).
- Yazğılı, E., ve Baykara, M. (2022). Türkçe metinlerde makine öğrenmesi yöntemleri ile siber zorbalık tespiti. *Gümüřhane Üniversitesi Fen Bilimleri Dergisi*, 12 (2), 443-453.