




Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Duygu Analizi ve Topluluk Öğrenmesi Yaklaşımları ile Kullanıcı Yorumlarının Analizi

 Adham Jolosı Jolosı ZADA ^a,  Ahmet ALBAYRAK ^{b,*}

^a Siber Güvenlik ABD, Lisansüstü Eğitimi Enstitüsü, Düzce Üniversitesi, Düzce, TÜRKİYE

^b Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Düzce Üniversitesi, Düzce, TÜRKİYE

* Sorumlu yazarın e-posta adresi: ahmetalbayrak@duzce.edu.tr

DOI: 10.29130/dubited.1102181

ÖZ

Bu çalışmada doğal dil işleme yaklaşımlarından olan duygu analizi teknikleri kullanılarak çevrimiçi alışveriş platformlarında ürün satın almış kullanıcıların yaptıkları yorumlar analiz edilmiştir. Türkiye’de yıllardır çevrimiçi alışveriş platformu olarak bilinen bir platformdan alınan kullanıcı yorumları üzerinde duygu analizi yapılmıştır. İlk olarak belirli bir kategoride 2237 yorum toplanmıştır. Yorumların üzerinde temel doğal dil işleme teknikleri işletilmiş, veriler temizlenmiş ve analiz edilecek hale getirilmiştir. Ardından veri seti üzerinde duygu analizi ile kullanıcıların vermiş oldukları puanlar karşılaştırılmıştır. Kullanıcı yorumları sınıflandırılırken topluluk öğrenme tekniklerinden Random Forest ve AdaBoost yaklaşımları denenmiştir. Çalışma sonucunda kullanıcı yorumlarının verilen puan ile tutarlı olmadığını görülmüştür. Kullanıcıların verdikleri puanlar ile yaptıkları yorumların en uyumlu olduğu dört yıldız verilen kategori olmuştur. Bu nedenle çevrimiçi alışveriş platformlarının kullanıcı yorumlarını toplarken daha nitelikli toplaması ve yorumların geçerlilikleri üzerine sistem geliştirmeleri, makine öğrenmesi ve doğal dil işleme tekniklerini sistemlerine entegre etmeleri gerektiği sonucuna varılmıştır.

Anahtar Kelimeler: Duygu Analizi, Topluluk Öğrenmesi, Random Forest Regresyon, AdaBoost Regresyon

Analysis of User Comments with Sentiment Analysis and Ensemble Learning Approaches

ABSTRACT

In this study, the comments made by users who purchased products on online shopping platforms were analyzed by using sentiment analysis techniques, which is one of the natural language processing approaches. Sentiment analysis was conducted on user comments received from a platform known as an online shopping platform in Turkey for years. Initially, 2237 comments were collected in a specific category. Basic natural language processing techniques were operated on the comments, the data was cleaned and made available for analysis. Then, the scores given by the users were compared with the sentiment analysis on the data set. While classifying user comments, Random Forest and AdaBoost approaches from community learning techniques were tried. As a result of the study, it was seen that the user comments were not consistent with the given score. The four-star category was the one with the most consistent ratings and comments made by the users. For this reason, it has been concluded that online shopping platforms should collect user comments in a more qualified way and develop systems on the validity of comments, integrate machine learning and natural language processing techniques into their systems.

Keywords: Sentiment Analysis, Ensemble Learning, Random Forest Regression, AdaBoost Regression

I. GİRİŞ

Doğal Dil İşleme (Natural Language Processing- NLP), var olan dillerin kurallı yapısının çözümlenerek sayısallaşması veya yeniden üretilmesi amacıyla geliştirilmiştir. Bu tekniğin getireceği kolaylıklar arasında yazılı belgelerin otomatik çevrilmesi, soru-cevap şeklinde çalışabilecek makineler, otomatik konuşma, komut anlama, konuşmaların sentezi, konuşma üretme, otomatik metin özetleme, bilgi çıkarma gibi birçok başlıkla özetlenebilmektedir. Bilgisayar teknolojilerinin yoğun kullanımı, bu başlıklardan üretilen uzman yazılımların gündelik hayatımızın her alanına girmesini sağlamıştır. Örneğin, mobil telefon yazılımları birer imlâ düzeltme aracı barındırmaktadır. Ayrıca sürekli iyileşen çeviri yazılım araçları da örnek verilebilmektedir. Bu araçlar aslında yazılan metni çözümleyerek dil kurallarını denetleyen doğal dil işleme yazılımlarıdır [1, 2].

Duygu analizi, duygusal durumları ve öznel bilgileri sistematik olarak tanımlamak, çıkarmak, ölçmek ve incelemek için kullanılmaktadır. Doğal dil işleme, metin analizi, hesaplamalı dilbilim ve biyometrinin kullanılmasını içermektedir. Duygu analizi, incelemeler ve anket yanıtları, çevrimiçi ve sosyal medya gibi kullanıcı verileri, pazarlamadan müşteri hizmetlerine ve klinik tıba kadar uzanan uygulamalar için sağlık hizmetlerinde yaygın olarak kullanılmaktadır [3, 4]. Duygu analizindeki temel görev, belirli bir metin kutupluluğunu (belge cümle veya özellik/boyut düzeyinde) bir belgede, bir cümlede veya bir varlık özelliği/boyutunda ifade edilen görüşün olumlu, olumsuz veya tarafsız olup olmadığını sınıflandırmaktır. Bilgisayarlar gibi iki sınıflı (1,0) sınıflandırmanın aksine duygu sınıflandırması (zevk, öfke, iğrenme, üzüntü, korku ve şaşkınlık) gibi duygusal durumlar elde edebilmektedir [5, 6].

Duygu analizinin öncüleri, metindeki kalıpları sayısallaştırmaya yönelik ipuçları sağlayan General Inquirer tarafından sözlü davranışların analizine dayalı olarak psikolojik durumu inceleyen psikolojik araştırmalar yapmıştır. Daha sonra, Volcani ve Fogel'in bir çalışmasında özellikle duyguya bakmış ve farklı duygusal ölçeklere göre metindeki tek tek kelimeleri ve cümleleri belirlemiştir. EffectCheck adı verilen çalışmalarına dayalı güncel bir sistem, her ölçekte duygu düzeyini artırmak veya azaltmak için kullanılabilir eş anlamlı sözcükler sunmaktadır [7, 8]. Sırasıyla ürün incelemelerinin ve film incelemelerinin kutupluluğunu tespit etmek için farklı yöntemler uygulayan Turney ve Pang'in çalışması gibi, olumludan olumsuzla yalnızca kutupsal bir duygu bakış açısı elde etmek oldukça basit olmaktadır. Çoğu istatistiksel sınıflandırma yöntemlerinde, nötr metinlerin ikili sınıflandırıcının sınırına yakın olduğu varsayımı altında nötr sınıf göz ardı edilse de birçok araştırmacı, her polarite probleminde olduğu gibi üç kategorinin tanımlanması gerektiğine inanmaktadır. Nötr bir sınıfla çalışmanın prensipte iki yolu vardır. Algoritma ya önce nötr dili belirleyerek, onu filtreleyerek ve ardından geri kalanını olumlu ve olumsuz duygular açısından değerlendirerek ilerler ya da tek adımda üç yönlü bir sınıflandırma oluşmaktadır [7]. Bu ikinci yaklaşım genellikle tüm kategoriler üzerinde bir olasılık dağılımının tahmin edilmesini içermektedir. Nötr bir sınıfın kullanılıp kullanılmaması ve nasıl kullanılacağı verinin doğasına bağlıdır, eğer veriler açıkça nötr, negatif ve pozitif dil olarak kümelenmişse, nötr dili filtrelemek ve pozitif-negatif duygular arasındaki kutupluluğa odaklanmak mantıklıdır. Buna karşılık, veriler olumlu ve olumsuz etkilere yönelik küçük sapmalarla çoğunlukla nötr ise, bu strateji iki kutup arasında net bir şekilde ayırım yapmayı zorlaştıracaktır [6][9, 10]. Duyarlılığı belirlemek için farklı bir yöntem, genellikle olumsuz, nötr veya olumlu bir duyguya sahip olmakla ilişkilendirilen sözcüklere -10 ile +10 ölçeğinde (en olumsuzdan en olumluya) ilişkili bir sayı verildiği bir ölçeklendirme sisteminin kullanılmasıdır.

Bu, belirli bir terimin çevresine göre duyarlılığını ayarlamayı mümkün kılmaktadır. Yapılandırılmamış bir metin parçası, doğal dil işleme kullanılarak analiz edildiğinde, belirtilen ortamdaki her bir kavrama, duygu sözcüklerinin kavramla ilişkisine ve bununla ilişkili puana dayalı olarak bir puan verilmektedir. Bu, daha karmaşık bir duygu anlayışına doğru harekete izin verir çünkü artık bir kavramın duygu değerini, onu çevreleyen değişikliklere göre ayarlamak mümkün hale gelmektedir. Alternatif olarak, amaç metnin genel kutupluluğu ve gücünden ziyade bir metindeki duyguyu belirlemekse, metinlere olumlu ve olumsuz bir duygu gücü puanı verilebilmektedir [3][11]. Duygu analizine yönelik mevcut yaklaşımlar üç ana kategoride gruplandırılabilir: bilgiye dayalı teknikler, istatistiksel yöntemler ve hibrit

yaklaşımlar. Bilgiye dayalı teknikler metni, mutlu, üzgün, korkmuş ve sıkılmış gibi belirsiz duygu sözcüklerinin varlığına dayalı olarak duygu kategorilerine göre sınıflandırmaktadır [12]. İstatistiksel yöntemlerde, gizli anlamsal analiz, destek vektör makineleri, kelime torbası yaklaşımı (Bag of Words), noktasal karşılıklı bilgi (Semantic Orientation) ve derin öğrenme gibi makine öğrenimi yaklaşımları kullanılmaktadır. Hibrit yaklaşımlar ise, anlambilimi saptamak için ilgili bilgileri açıkça iletmeyen, ancak dolaylı olarak bağlantılı olan kavramların analizi yoluyla hem makine öğreniminden hem de ontolojiler ve anlamsal ağlar gibi bilgi temsilinden öğelerden yararlanmaktadır. Bir duygu analizi sisteminin doğruluğu prensipte, insan yargılarıyla ne kadar iyi uyduğu ile ölçülebilmektedir [13].

Duygu analizi televizyon kanalları üzerinden satışı yapılan ürünler için gerçekleştirilen reklamların analiz edilmesinde kullanılmıştır. Reklamların müşteri üzerindeki etkisini anlayabilmek ve gelecek ile ilgili yorum yapabilmek için reklamlar ile ilişkili sosyal medya üzerinden toplanan veriler analiz edilmiştir. Twitter kullanıcılarının (Haziran- Kasım 2017) televizyon yayınları hakkındaki duygu ve düşünceleri pozitif, negatif veya nötr olma durumu incelenmiştir. Araştırma sonucunda elde edilen bulgulara göre televizyon kanallarındaki programların izleyici görüşlerine göre değiştiği gözlemlenmiştir [12]. Bu çalışmanın amacı özellikle salgın döneminde kullanımı artan e-ticaret platformlarında satılan ürünlere yapılan yorumların ve verilen puanların ne kadar tutarlı olduğunu araştırmaktır. Bu çalışma materyal ve metot, deneysel çalışma ve sonuç bölümlerinden oluşmaktadır.

II. MATERYAL VE METOD

Bu çalışmada doğal dil işleme teknikleri kullanılarak duygu analizi yapılmış ve kullanıcı yorumları analiz edilmiştir. Geliştirilen sistemin blok şeması Şekil 1’de verilmektedir. Şekil 1’de de verildiği gibi ilk olarak ülkemizde önemli bir e-ticaret platformundan kullanıcı yorumları alınmıştır. Yorumlar el ile toplanmış ve toplam 2237 yorum kaydedilmiştir. Toplanan yorumlar ham veri formatındadır yani yapılandırılmamış veri yapısındadır. Yapılandırılmamış veri seti ön işleme adımı ile anlam ifade etmeyen, duygu analizi için kullanılmayan ifadeler çıkarılmıştır. Her yoruma benzersiz bir nitelik alanı eklenmiştir. id, ürün bilgisi, yorum içeriği ve kullanıcının verdiği puan şeklindeki değişkenlerden/sütunlardan oluşacak şekilde csv uzantılı dosyaya kaydedilmiştir. Bu aşamada veri seti yapılandırılmış veri formuna dönüşmüştür.

Veri temizleme adımında istenmeyen kelime ve karakterlerin ayrıştırılması amacıyla yapılmıştır. Veri temizleme işlemi yapılmaması durumunda gürültülü ve tutarsız veriler ile çalışmak doğru bir sonuca ulaşılmasını engellemektedir. Bu adımda noktalama işaretleri, özel karakterler, sayılar ve istenilen metin dışındaki kelimeler temizlenerek gürültüsüz veri seti elde edilmiştir. Geliştirilen uygulama Jupyter ortamında kodlanmıştır. Jupyter Notebook, çeşitli programlama dilleri için etkileşimli bir ortam sağlayan açık kaynak kodlu bir programdır. Bu çalışmada duygu analizi için Python NLTK paketi kullanılmıştır.

NLTK, makine öğrenimi yeteneklerine başvurmadan önce metni anlamlı bir şekilde analiz etmeye yardımcı olacak çok az argümanla veya hiç argüman kullanmadan arayabilecek bir dizi fonksiyon sağlamaktadır. Veri temizleme işleminden sonra veri seti üzerinde sözcüklerin sıklık analizi yapılmıştır. Bu işlemler VADER (Valence Aware Dictionary ve Entiment Reasoner) aracılığıyla yapılmıştır [14]. VADER özellikle sosyal medyada ifade edilen duygulara uyum sağlayan, sözlük ve kural tabanlı bir duygu analizi aracıdır. Olumlu/olumsuz her iki kutbu da olan metnin duygu analizi için kullanılır. Verileri görselleştirerek tipografik kelime bulutu için ise WordCloud kütüphanesi kullanılmıştır. Pyplot kütüphanesi ve uzantıları sayesinde veriler görselleştirilmiştir. Şekil 2’de örnek bir kelime bulutu paylaşılmaktadır.

NLTK, duygu analizi de dâhil olmak üzere çeşitli analiz türleri için uygun olan birkaç yerleşik sınıflandırıcı barındırmaktadır. Önemli olan veri kümesine uygun sınıflandırıcıyı bulmaktır. Makine öğrenimi dünyasında bu özellikler, verilerle çalışırken ortaya çıkarılması ve seçilmesi gereken özellikler olarak bilinmektedir. NLTK'nin tüm kelimeleri daha doğru şekilde etiketleyebilmesi için kelime listeleri filtrelemeden önce `pos_tag()` ögesini çağırılmıştır. Bu özellikler listesindeki her ögenin, ilk ögesi `extract_features` tarafından döndürülen sözlük olan ve ikinci ögesi metin için önceden tanımlanmış kategori olan bir satırdır. Sınıflandırıcıyı önceden kategorize edilmiş bazı verilerle eğittikten sonra yeni veriler sınıflandırılabilir. Özellik listesi karıştırıldığı için her çalıştırmada farklı sonuçlar vermektedir. NLTK, popüler makine öğrenimi çerçevesi scikit-learn sınıflandırıcıdan çoğu sınıflandırıcıyı kullanabilmektedir [16].

III. DENEYSEL ÇALIŞMA

NLTK, scikit-learn sınıflandırıcılarını doğrudan kendi sınıflandırıcı sınıfına entegre etmeye izin verdiğinden, eğitim ve sınıflandırma süreçleri için `train()` ve `classify()` yöntemleri kullanılabilir. Özellikler listesi, ilk ögesi `extract_features()` tarafından verilen bir dizi özellik ve ikinci ögesi `user_reviews` veri setindeki önceden sınıflandırılmış (kullanıcı puanları) verilerden sınıflandırma etiketi olan kayıtları içermektedir. Her bir scikit-learn sınıflandırıcı için, NLTK sınıflandırıcısı oluşturmak amacıyla `nlk.classify.SklearnClassifier` eklenir.


`.train()` ve `.accuracy()` yöntemleri, aynı özellik listesinin farklı bölümlerini almaktadır. Burada Random forest ve AdaBoost teknikleri sınıflayıcı olarak kullanılmıştır. Elde edilen sonuçlarda karşılaştırılmıştır. İstatistik ve makine öğreniminde topluluk yöntemleri, tek başına herhangi bir kurucu öğrenme algoritmasından elde edilebilecek olandan daha iyi tahmine dayalı performans elde etmek için çoklu öğrenme algoritmaları kullanılmaktadır.

İstatistiksel mekanizmada genellikle sonsuz olan istatistiksel bir topluluğun aksine, bir makine öğrenimi topluluğu yalnızca somut bir sonlu alternatif model kümesinden oluşur, ancak tipik olarak bu alternatifler arasında çok daha esnek bir yapının var olmasına izin vermektedir [17- 19]. Random forest eğitim zamanında çok sayıda karar ağacı oluşturarak çalışan sınıflandırma, regresyon ve diğer görevler için bir topluluk öğrenme yöntemidir. Sınıflandırma görevleri için Random forest çıktısı, çoğu ağaç tarafından seçilen sınıftır. Regresyon görevleri için tek tek ağaçların ortalama tahmini döndürülmektedir [20].

Adaptive Boosting'in kısaltması olan AdaBoost, bir istatistiksel sınıflandırma meta-algoritmasıdır. Performansı artırmak için diğer birçok öğrenme algoritması türüyle birlikte kullanılabilir. Diğer öğrenme algoritmalarının ('zayıf öğrenenler') çıktısı, güçlendirilmiş sınıflandırıcının nihai çıktısını temsil eden ağırlıklı bir toplamda birleştirilmektedir.


AdaBoost, sonraki zayıf öğrencilerin önceki sınıflandırıcılar tarafından yanlış sınıflandırılan örnekler lehine ayarlanması anlamında uyarlanabilmektedir. Bazı problemlerde, diğer öğrenme algoritmalarına göre fazla uydurma problemine daha az duyarlı olabilmektedir. Bireysel öğrenenler zayıf olabilir, ancak her birinin performansı rastgele tahminden biraz daha iyi olduğu sürece, nihai modelin güçlü bir öğreniciye yakınsadığı söylenebilmektedir [21].

Bu çalışmada kullanıcı yorumlarının duygu analizi ile puanlanması sonucu elde edilen puanlar için Random forest ve AdaBoost teknikleri sınıflama amacıyla kullanılmıştır. Şekil 3'te Random forest ile yapılan tahmin sonuçları verilmektedir. Her bir puan kategorisi için algoritmalar tekrar tekrar çalıştırılmıştır.



Şekil 3. *Random forest tahmin sonuçları.*

Şekil 3'te de verildiği gibi Random forest algoritması ile yapılan tahminlerde en yüksek başarıım 4. Kategoride elde edilmiştir (%87,9). Şekil 4'te ise AdaBoost algoritması sonuçları verilmektedir.



Şekil 4. *AdaBoost tahmin sonuçları.*

Şekil 4'te verilen AdaBoost algoritması sonuçlarında en iyi tahmin Random forest algoritmasında olduğu gibi 4. kategoride gerçekleşmiştir (%79,6). Şekil 3 ve Şekil 4'te de verildiği gibi kullanıcı puanlarının yoğun biçimde 5. kategoride yer almasına karşın her iki algoritmanın sonuçlarına bakıldığında 4. kategoriye daha fazla puan verildiği görülmektedir. Bu kullanıcı yorumları ile verilen puanların uyumlu olmadığını ifade etmektedir.

IV. SONUÇ

Alışveriş platformları alışveriş yapan kullanıcıların ürünlerini teslim almalarını takiben, sipariş süreci ile ilgili hem yorum hem de 1-5 arası yıldız ile puan vermesini istemektedir. Kullanıcıların yaptıkları yorumların verdikleri puan ile uyumlu olması halinde yorumların geçerliliği anlamında önemlidir. Kullanıcılar ürün satın alırken ürünün özelliklerini inceledikten sonra hem ürün hem de sipariş süreci

ile ilgili yorum yapan kullanıcı yorumlarını okumaktadır. Şekil 3 ve 4 incelendiğinde kullanıcı puanı ile tahmin edilen puanların birbirlerine en yakın olduğu kategoriler ve en gerçekçi yorumları içermektedir. Şekil 3 ve 4'te dördüncü kategori haricinde diğer tüm kategorilerde ve denenen iki teknikte de kullanıcı puanları tahmin puanından yüksek olarak tespit edilmiştir. İki tekniğin de kategoriler bazında benzer sonuçlar vermesi, iki tekniğinde bu sorun alanında kullanılabilceğini göstermektedir. Buna ek olarak iki teknikte dördüncü kategoride kullanıcıların verdikleri puanlar ile yaptıkları yorumların geçerliliğinin daha doğru olduğu sonucunu vermektedir. Diğer tüm kategorilerde ise yorumlar ve puanlar arasında büyük tutarsızlık olduğu görülmüştür.

Bu çalışmada son yıllarda tüm dünyada yaşanan Covid-19 salgını sürecinde ülkemizde de artan hacmi ile e-ticaret platformlarında kullanıcı yorumları analiz edilmiştir. Kullanıcı yorumları duygu analizi teknikleri ile analiz edilmiştir. Ardından kullanıcıların yaptıkları yorumlar ile verdikleri puanların karşılaştırılması için Random forest ve AdaBoost topluluk öğrenme teknikleri kullanılmıştır. Şekil 3 ve Şekil 4'te verildiği gibi kullanıcı yorumları ile verilen puanların uyumlu olmadığı görülmüştür. Bu nedenle e-ticaret platformlarının kullanıcı yorumlarını toplarken makine öğrenmesi ve doğal dil işleme tekniklerini sistemlerine entegre etmeleri gerektiği sonucuna varılmıştır.

E-ticaret platformları özellikle Covid-19 salgını sürecinde satış hacimlerini olağanüstü oranda artırmıştır. 2019 yılına göre (136 milyar TL) 2020 yılında e-ticaret platformlarında yurt içinde %66'lık artış (226,2 milyar TL) olmuştur. Böylesi bir artış ve ticaret hacminin olduğu e-ticaret platformlarının elde ettikleri bu potansiyeli devam ettirebilmeleri için kullanıcılardan aldıkları geri bildirimleri iyi analiz etmeleri ve değerlendirmeleri gerekmektedir.

Bu çalışmada da görüldüğü gibi kullanıcı yorumları ve verilen puanlar diğer kullanıcılar için yanıltıcı olabilmektedir. Bu çalışmanın devamında e-ticaret platformları için kullanıcı verilerinin toplanması için prototip bir sistem tasarımı yapılacaktır. Çalışmada doğal dil işleme teknikleri, duygu analizi ve makine öğrenmesi yaklaşımları kullanılacaktır.

V. KAYNAKLAR

- [1] Albayrak A., "Preparing Interdisciplinary Graduate Course Contents Using Natural Language Processing Techniques," *Gazi Bilişim Teknolojileri Dergisi*, pp. 373–383, doi: 10.17671/gazibtd.714447, 2020
- [2] M. Giménez, J. Palanca, and V. Botti, "Semantic-based padding in convolutional neural networks for improving the performance in natural language processing. A case of study in sentiment analysis," *Neurocomputing*, vol. 378, pp. 315–323, doi: 10.1016/j.neucom.2019.08.096 , 2020
- [3] Bostancı B., and Albayrak A., "Duygu Analizi İle Kişiyeye Özel İçerik Önermek", *Veri Bilimi Dergisi*, vol. 4, no. 1, pp. 53–60, 2021.
- [4] Akın B., and Şimşek Umman T., "Social Media Analytics: Value Creation With Sentiment Analysis Analysis", *Journal of Mehmet Akif Ersoy University Faculty of Economics and Administrative Sciences*, pp. 1–14, 2017.
- [5] P. Sasikala and L. M. I. Sheela, "Sentiment analysis of online product reviews using DLMNN and future prediction of online product using IANFIS," *J. Big Data*, doi: 10.1186/s40537-020-00308-7 , 2020
- [6] I. Chaturvedi, E. Cambria, R. E. Welsch, and F. Herrera, "Distinguishing between facts and opinions for sentiment analysis : Survey and challenges," *Inf. Fusion*, vol. 44, no. June 2017, pp. 65–77, 2018, doi: 10.1016/j.inffus.2017
- [7] Y. Mehmood and V. Balakrishnan, "An enhanced lexicon-based approach for sentiment

analysis: a case study on illegal immigration,” *Online Information Review* vol. 44, no. 5, pp. 1097–1117, doi: 10.1108/OIR-10-2018-0295, 2020

[8] C. Troussas, M. Virvou, K. J. Espinosa, K. Llaguno, and J. Caro, “Sentiment analysis of Facebook statuses using Naive Bayes Classifier for language learning,” *IISA 2013 - 4th Int. Conf. Information, Intell. Syst. Appl.*, pp. 198–205, doi: 10.1109/IISA.2013.6623713, 2013

[9] I. Yahav, O. Shehory, and D. Schwartz, “Comments Mining With TF-IDF: The Inherent Bias and Its Removal,” *IEEE Trans. Knowl. Data Eng.*, vol. 31, no. 3, pp. 437–450, doi: 10.1109/TKDE.2018.2840127, 2019.

[10] B. Ayan, B. Kuyumcu, and B. Cıylan, “Detection of Islamophobic Tweets on Twitter Using Sentiment Analysis,” *Gazi Bilişim Teknolojileri Dergisi*, vol. 7, no. 2, pp. 495–502, doi: 2019.

[11] E. S. Akgül, C. Ertano, and B. Diri, “Sentiment analysis with Twitter,” *Pamukkale Univ. J. Eng. Sci.*, vol. 22, no. 2, pp. 106–110, doi: 10.5505/pajes.2015.37268, 2016

[12] B. Akın and U. T. GÜR SOY ŞİMŞEK, “Sosyal Medyanın Analizi ile Değer Yaratma: Duyguların Analizi ile Geleceğe Yönelim,” *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilim. Fakültesi Derg.*, pp. 797–811, doi: 10.30798/makuiibf.435804, 2018

[13] C. Aydın, “Classification of fire station requirement using machine learning algorithms,” *European Journal of Science and Technology*, no. 14, pp. 169–175, doi: 10.31590/ejosat.458613, 2018.

[14] H. Tang, S. Tan, and X. Cheng, “Expert Systems with Applications A survey on sentiment detection of reviews,” *Expert Syst. Appl.*, vol. 36, no. 7, pp. 10760–10773, doi: 10.1016/j.eswa.2009.02.063, 2009.

[15] G. G. Sundarkumar and V. Ravi, “Engineering Applications of Artificial Intelligence Brief paper A novel hybrid undersampling method for mining unbalanced datasets in banking and insurance,” *Eng. Appl. Artif. Intell.*, vol. 37, pp. 368–377, doi: 10.1016/j.engappai.2014.09.019, 2015.

[16] J. Villanu and A. Lo, “Neurocognitive disorder detection based on feature vectors extracted from VBM analysis of structural MRI,” *Comput Biol Med* vol. 41, pp. 600–610, doi: 10.1016/j.combiomed.2011.05.010, 2011.

[17] T. Vidal and M. Schiffer, “Born-Again Tree Ensembles,” *37th International Conference on Machine Learning (ICML)*. Vol. 119, pp. 9743–9753, 2020.

[18] H. Liu and L. Zhang, “Advancing Ensemble Learning Performance through data transformation and classifiers fusion in granular computing context,” *Expert Syst. Appl.*, vol. 131, pp. 20–29, doi: 10.1016/j.eswa.2019.04.051, 2019

[19] M. Saarela and S. Jauhiainen, “Comparison of feature importance measures as explanations for classification models,” *SN Appl. Sci.*, vol. 3, no. 2, pp. 1–12, doi: 10.1007/s42452-021-04148-9, 2021.

[20] S. Kar et al., “An ensemble machine learning approach for determination of the optimum sampling time for evapotranspiration assessment from high-throughput phenotyping data,” *Comput. Electron. Agric.*, vol. 182, no. doi: 10.1016/j.compag.2021.105992, June 2020, 2021

[21] S. Lahmiri, S. Bekiros, A. Giakoumelou, and F. Bezzina, “Performance assessment of ensemble learning systems in financial data classification,” *Intell. Syst. Accounting, Financ. Manag.*, vol. 27, no. 1, pp. 3–9, doi: 10.1002/isaf.1460, 2020.