



Bankacılık Sektörü için Topluluk Öğrenimini Kullanan iki Aşamalı bir Müşteri Şikâyet Yönetimi

A Two-Step Customer Complaint Management Using Ensemble Learning for The Banking Industry

Muhammed Mehmet AKGÜMÜŞ

*İstanbul Ticaret Üniversitesi
Mühendislik Fakültesi
İstanbul, Türkiye*

mehmet.ahgumus@istanbulticaret.edu.tr
ORCID: 0000-0002-3152-6959

Ali BOYACI

*İstanbul Ticaret Üniversitesi
Mühendislik Fakültesi
İstanbul, Türkiye*

aboyaci@ticaret.edu.tr
ORCID: 0000-0002-2553-1911

Öz

Bu çalışmada; bankacılık sektöründe müşterilerden gelen her türlü bildirimlerin sınıflandırılması, sonrasında bu sınıfların önceliklendirilmesi ve bu önceliğe göre müşteriye geri bildirim verilmesi amaçlanmıştır. Bu sayede müşteri memnuniyeti sağlayacak öncelikli bildirimlere hızlı çözüm üretilebilmesi hedeflenmiştir. Verilerin sınıflandırılmasıyla ilgili yapılan literatür taramasında yüksek doğruluk değerlerinin; Lojistik Regresyon, Uzun Kısa Süreli Bellek, Multinomial Naive Bayes ve Destek Vektör Makinesi algoritmaları ile elde edildiği gözlemlenmiştir. Bu sebeple bu algoritmalarla gerçek bir banka veri seti üzerinde Doğal Dil İşleme (Natural Language Processing - NLP) yöntemleri kullanılarak eğitim ve sınav işlemleri gerçekleştirilmiştir. Yeni bir yöntem olarak sunulan iki aşamalı yaklaşımla sınırlı sayıda veri setiyle çalışılarak doğruluk değerlerini yüzde yetmişin üzerine çıkarılması başarılmıştır.

Anahtar sözcükler: Doğal Dil İşleme, Makine Öğrenimi, Türkçe Metin Sınıflandırma, Müşteri Memnuniyeti, Lojistik Regresyon, Destek Vektör Makinesi, Uzun Kısa Süreli Bellek, Multinomial Naive Bayes

Abstract

In this study; It is aimed to classify all kinds of notifications from customers in the banking sector, then prioritize these classes and give feedback to the customer according to this priority. In this way, it is aimed to produce quick solutions for priority notifications that will ensure customer satisfaction. In the literature review on the classification of data, high accuracy values; It has been observed that it is obtained by Logistic Regression, Long Short Term Memory (LSTM), Multinomial Naive Bayes and Support Vector Machine (SVM) algorithms. For this reason, training and testing processes were carried out using Natural Language Processing (NLP) methods on a real bank data set with these algorithms. With the two-stage approach presented as a new method, it has been achieved to increase the accuracy values above seventy percent by working with a limited number of data sets.

Keywords: Natural Language Processing, Machine Learning, Turkish Text Classification, Customer Satisfaction, Logistic Regression, Support Vector Machine, Long Short Term Memory, Multinomial Naive Bayes

1. Giriş

Türkiye'de bankacılık sektörü gelişmeye ve büyümeye devam etmektedir. Müşterilerine en iyi hizmeti sunmak için oldukça rekabetçi bir ortamda faaliyet gösteren çok sayıda banka bulunmaktadır. Bu rekabet ortamında müşteri taleplerine en

hızlı şekilde cevap vermek esastır. Bu kapsamda dört farklı bankanın şikâyet yönetiminin iyileştirilmesine yönelik bir çalışma yapılmıştır [1]. Ayrıca Endonezya'da kamu bankalarının bankacılık hizmetlerine müşteri şikâyetlerinin etkisini incelemek için yapılan çalışmalarda şikâyet yönetiminin müşteri sadakati ve memnuniyeti üzerinde önemli bir etkiye sahip olduğu sonucuna varılmıştır [2] [3].

Türkiye'deki bankaların mevduat payları ve şikâyet oranları incelendiğinde, şikâyetlerin sistemli bir şekilde yönetilmesinin ve müşterilerin memnuniyetinin bankaların nakit akışlarının devamlılığında önemli rol oynadığı iddia edilmektedir [4]. Harkiranpal Singh'in birçok araştırmacı ve akademisyenin görüş ve araştırmalarına dayanarak yaptığı çalışmada, müşteri memnuniyetinin kurumlar için olmazsa olmaz kriterlerden biri olduğu sonucuna varılmıştır [5]. Bu nedenle müşteri memnuniyeti, müşteriler için ürünü tekrar satın alma garantisini vermesi bile müşteri sadakati ve müşteriyi elde tutmada kritik bir rol oynamaktadır. Kuruluşlar, müşterilerinin ürünlerinden memnun olmalarını sağlamak için çaba göstermelidir. Ayrıca, kullanıcı şikâyet verileri bir banka için Anahtar Performans Göstergesi (KPI) olarak kullanılabilir. Müşteri memnuniyeti de kullanıcı şikâyetleri ile yüksek oranda ilişkilidir. Müşteriler ne kadar memnun olursa, şikâyetlerinin o kadar az olduğu açıktır. Müşteri memnuniyeti için yapılan bir çalışmada bu KPI'lar kullanılarak müşteri puan kartı oluşturulur [6].

Müşteri şikâyetlerinin ve taleplerinin yönetiminde müşterilerden bankaya gelen; banka uygulamaları hakkındaki problem kayıtları, müşteri işlemleriyle ilgili istekler ve müşterilerin banka uygulamaları hakkında sorularının ayrıştırılması ve hızlı şekilde müşteriye ulaşılması önem arz etmektedir.

2. Kaynak Taraması

Telekom ve internet servis sağlayıcı şirketi için yapılan bir araştırma, müşterilerin seslerinden özellikle öfke ve mutluluk olmak üzere kullanıcı duygularını doğru bir şekilde tanımlanabildiğini gösteriyor [7]. Bu tanımlama, bireysel müşteriler için uygun bir yaklaşım oluşturmaya yardımcı olabilir. Ek olarak, bu bilgiler şirketlerin kullanıcı memnuniyetine yardımcı olabilecek özel müşteri hizmetlerine sahip olmalarına yardımcı olabilir.

Başka bir çalışmada ise İngilizce ve Tagalog dilinde 1752 kayıttan oluşan veri seti üzerinde müşteri şikâyetlerinin sınıflandırılması yapılmıştır [8] [9]. Bu çalışmalarda müşteri şikâyetleri için uluslararası bir kalite standardı bulunmaktadır. Çalışmada veri seti dört kategoriye ayrılmıştır (geri bildirim, şikâyet, övgü ve öneri). Bu çalışma sonucunda doğruluk değeri SVM algoritması ile %98,63, LSTM algoritması ile %99,32 olarak ölçülmüştür. Ancak verilen değerler sadece eğitim adımlarının sonuçları olduğu için belirsizdir.

Rachmawan Adi Laksono ve diğerleri tarafından yapılan bir araştırma sonucuna göre, finans sektöründeki para akışının daha yüksek olmasına ve en ufak bir problemin neden olabileceği durumlara neden olabileceğinden, bankalar gibi finans sektöründe hizmet veren kurumlar için şikâyet

yönetimi daha kritiktir. İlgili kuruma maliyeti çok yüksek olabilir [10].

Araştırmalar, müşteri şikâyetlerini etkin bir şekilde yönetmek için verilerin uygun şekilde sınıflandırılması gerektiğini göstermektedir. Bu sınıflandırma Doğal Dil İşleme yöntemleri kullanılarak yapılabilir. Doğal dil işlemede sıklıkla kullanılan yöntemlerden biri, Zellig Haris'in tanıttığı; metindeki noktalama işaretlerini kaldırmak, sözcüklerin kökünü bulmak ve her metindeki sözcüklerden bir sözcük kesesi (Bag of Words - BoW) oluşturmaktır [11]. Bu yöntem ile veri setindeki her sözcüğün metinde geçme sıklığı bulunur. Bu yöntem, yazım hatalarının göz ardı edileceği varsayılarak çoğu dilde iyi çalışır. İncelenen bir çalışmada, metinleri ve görsel içerikleri sınıflandırmak için BoW yöntemi kullanılmıştır [12].

Metnin dili ve olası yanlış yazılmış sözcükler, sınıflandırmanın doğruluğunu etkiler. Diller yapılarına göre farklılık gösterir. Türkçe, Moğolca, Korece ve Japonca gibi diller sondan eklemeli diller grubuna girer. Sondan eklemeli diller, sözcüğün köküne son ekler ekleyerek farklı sözcükler oluşturabilir. Örneğin; "Süt" sözcüğü "-çü" ekini alarak "Sütçü" olur ve yeni bir sözcük oluşturur. Bu tür sondan eklemeli dillerde bir sözcüğün kökünü bulmak kolay değildir. Sondan eklemeli dillerin makine öğrenmesi ile morfolojik analizini yapan bir çalışmada, SVM algoritmasının diğer algoritmalarından daha iyi performans gösterdiği görülmüştür [13].

Çok sayıda şikâyet mesajı alan şirketler için zor ve bu mesajları sınırlı kaynaklarla işlemek zordur. Bu konu, kamu tarafından finanse edilen bir araştırma projesinin bir parçası olarak ele alınmıştır [14]. Şikâyet yönetimi NLP ile sınıflandırılarak otomatik bir yanıt sistemi tasarlanmıştır. Çeşitli uzmanlara göre bu sistemin uygulanabilir olduğu sonucuna varılsa da müşterilerden toplanan verilerle sınama edilmediği için doğruluğu tartışmaya açık kalmıştır.

Sosyal medyadan toplanan 12790 veriden oluşan Türkçe bir metin üzerinde yürütülen çalışmada [15], tüm deneylerde SVM kullanılmış ve duyarlılık analizinin güven düzeyini artırmak için ön çaprazlama uygulanmıştır. Pozitif, negatif ve nötr olmak üzere üç sınıfa ayrılan veri setinde %78 doğruluk elde edilmiştir.

Rohit Gavval et al. Kendini Organize Eden Özellik Haritası Birleşik Cihaz Hesaplama Mimarisi (CUDASOM) ile müşteri şikâyetlerinin Görsel Farkındalık Analizi için Kendini organize eden özellik haritası (SOM) özelliğini NVIDIA'nın paralel hesaplama platformu Birleşik Cihaz Hesaplama Mimarisi (CUDA)'ni kullanan tanımlayıcı-analitik bir çerçeve önerdi [16]. Önerilen modelin etkinliği, önde gelen dört Hint bankasının ürün ve hizmetlerine ilişkin müşteri şikâyet verileriyle kanıtlanmıştır. Modelin performansı, belgelerin iki vektör uzayı modeli temsili, yani terim frekansı gösterimi ve Terim Frekansı-Ters Belge Frekansı (TF-IDF) gösterimi ile karşılaştırılır. Modelin TF-IDF tabanlı Belge Terim Matrisi (DTM) ile frekans tabanlı DTM terimine göre daha spesifik bir segmentasyon ürettiğini belirtmişlerdir. Görselleştirme, CUDASOM'un ürünler-hizmetlerle ilgili şikâyetleri etkin bir şekilde farklı gruplara ayırdığını göstermektedir. Yazar algoritmanın ayrıca seri versiyona kıyasla önemli bir hızlanma

gösterdiğini ve büyük boyutlu verilerin daha hızlı analizi için faydalı olarak kabul edilebileceğini ifade etmiştir.

Deepak Gupta ve diğerleri tarafından yapılan bir çalışmada, kullanıcıların herhangi bir dilde geri bildirim yazabileceklerinden bahsedilmiştir. Bu nedenle uygun bilgiyi aramak genellikle zordur [17]. Özellikle geleneksel öznitelik tabanlı kontrollü bir modelde, ilgili öznitelikleri bulmak için ilgili dili anlamak gerektiğinden genel bir sistem oluşturmanın zor olduğu ifade edilmiştir. Bu problemlerin üstesinden gelmek için Evrişimli sinir ağı (CNN) ve Yinelemeli sinir ağı (RNN) tabanlı yaklaşımlar önerilmiştir. Bu teknikler, müşteri geri bildirim cümlelerini İngilizce, Fransızca, Japonca ve İspanyolca olarak analiz etmek için değerlendirildi. Çalışmada ifade edilen deneysel analiz, modellerin Doğal Dil İşleme Uluslararası Ortak Konferansı (International Joint Conference on Natural Language Processing - IJCNLP) Müşteri Geri Bildirim Analizi üzerine Paylaşılan Görev kurulumlarında dört dilde de iyi performans gösterdiğini göstermektedir. Bu model, IJCNLP Fransızca için %71,75 doğruluk oranıyla ikinci, diğer tüm diller için üçüncü sırada yer almıştır.

Metin sınıflandırmada sıklıkla kullanılan Lojistik Regresyon algoritması, bir sonucu belirleyen bir veya daha fazla bağımsız değişken içeren bir veri setini analiz etmek için kullanılan istatistiksel bir yöntemdir [18]. Lojistik Regresyon ile diğer bir sınıflandırma algoritması olan Multinomial Naive Bayes algoritmasının performansını karşılaştıran bir soru/yanıt uygulamasında Lojistik Regresyonun Multinomial Naive Bayes algoritmasından daha başarılı çalıştığı gözlemlenmiştir [19].

LSTM, Bir RNN mimarisidir [20]. Öğrenilen ilerleme kaydedildiğinde saklanan değerler değişmez. RNN'ler, nöronlar arasında ileri ve geri bağlantılara izin verir. Bir metin sınıflandırma çalışmasında CNN, alternatif RNN ve LSTM algoritmaları karşılaştırılmış ve LSTM'nin en iyi performansı gösterdiği belirtilmiştir [21].

Naive Bayes Algoritması, çalışma yöntemleri açısından farklılık gösterir. Metin sınıflandırmada en çok kullanılan yöntemlerden ikisi Multinomial Naive Bayes algoritması ve Bernoulli Naive Bayes algoritmasıdır. Bu iki algoritmanın karşılaştırıldığı bir metin sınıflandırma çalışmasında 312 kayıttan oluşan bir veri seti ön işleme tabi tutulmuş ve sonuç olarak Multinomial Naive Bayes algoritmasının çok az bir farkla başarılı bir şekilde çalıştığı görülmüştür [22]. Naive Bayes algoritması koşullu olasılıklara dayanır, hedef sınıfta belirli bir değer oluşma olasılığını inceler ve buna göre hedef sınıfın değerini tahmin eder.

SVM ilk olarak 1995 yılında Corina Cortes ve Vladimir Vapnik tarafından piyasaya sürüldü [23]. Sınıflandırma ve Regresyon problemleri için kullanılan en popüler Denetimli Öğrenme algoritmalarından biridir. Ancak, öncelikle Makine Öğrenimindeki Sınıflandırma problemleri için kullanılır. SVM algoritmasının amacı, yeni veri noktasını doğru kategoriye hızlı bir şekilde koyulabilmesi ve n-boyutlu uzayı sınıflandırmak için en iyi çizgi veya karar sınırını oluşturmaktır. Bu en iyi karar sınırına hiper düzlem denir. SVM, hiper düzlemin oluşturulmasına yardımcı olan uç noktaları (vektörleri) seçer. Bu uç durumlara destek vektörleri denir; bu

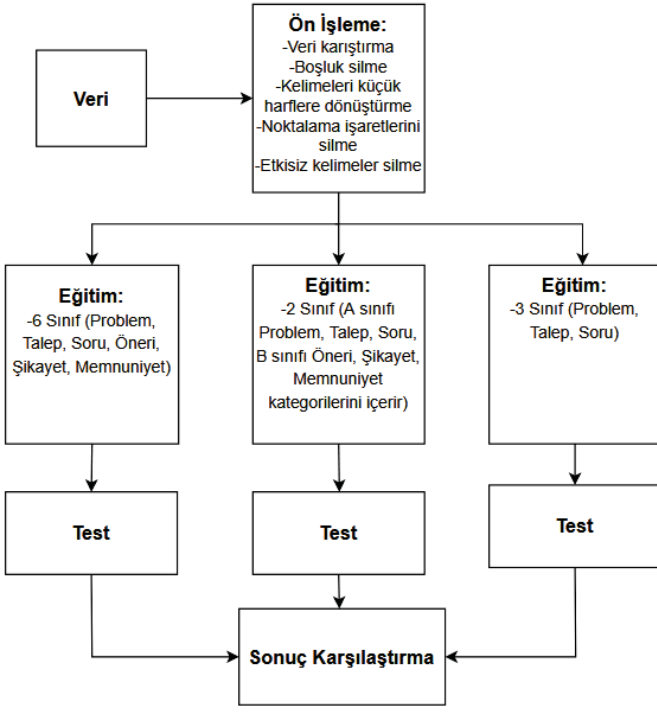
nedenle algoritma destek vektör makinesi olarak adlandırılır. K-En Yakın Komşu Algoritması (KNN), Naive Bayes ve SVM algoritmalarını karşılaştıran bir metin sınıflandırma çalışmasında, üç algoritma için yakın sonuçlar elde edilmesine rağmen, SVM'nin F1 Skoru, kesinlik ve geri çağırma değerlerinin daha üstün olduğu görülmüştür [24].

Bu çalışmada doğal dil işleme yöntemleri üzerine yapılan çalışmalar araştırılmış ve doğal dil işlemede kullanılan birçok algoritma incelenmiştir. Müşteri şikâyetlerinin analizi ve ayrıştırılmasına yönelik bu çalışmada Türkçe metinleri sınıflandırmak için farklı algoritmalar kullanıldı. Ancak belirlenen sınıf sayısının fazla olması nedeniyle algoritmaların elde ettiği doğruluk değerleri düşmüş ve istenilen sonuçlar elde edilememiştir. İlgili verilerin bankaya maliyetini ve müşteri memnuniyeti göz önünde bulundurularak mümkün olduğunca veri, en optimal şekilde sınıflandırılmaya çalışılmış ve sınıflara işlem aciliyeti belirlenerek öncelik verilmesi hedeflenmiştir. Bu nedenle çalışmada gerçek banka verilerinin daha detaylı bir sınıflandırılması yapılmış ve bu çalışmaları daha etkin uygulayabilecek ve önceliklendirilmesi istenen sınıflarda daha yüksek performans elde edebilecek bir yöntem sunulmuştur. Bu yöntem literatür taramasındaki tek aşamalı sınıflandırma yönteminden farklı olarak iki aşamada yapılarak hem doğruluğun artırılması hem de öncelikli ulaşılacak istenen kayıtların ayrıştırılmasını daha efektif sağlaması amaçlanmıştır.

Çalışmanın devamında: Metodoloji bölümü kullanılan veri seti, önerilen yöntem, veri sınıflandırma işleminin detayları hakkında bilgi vermekte, Sonuç bölümünde ise sonuçlar verilmektedir. Son olarak Sonuç bölümünde, elde edilen sonuçlar daha önce yapılmış çalışmalarla karşılaştırılmış ve ileriye dönük yapılabilecek çalışmalar ifade edilerek makale sonlandırılmıştır.

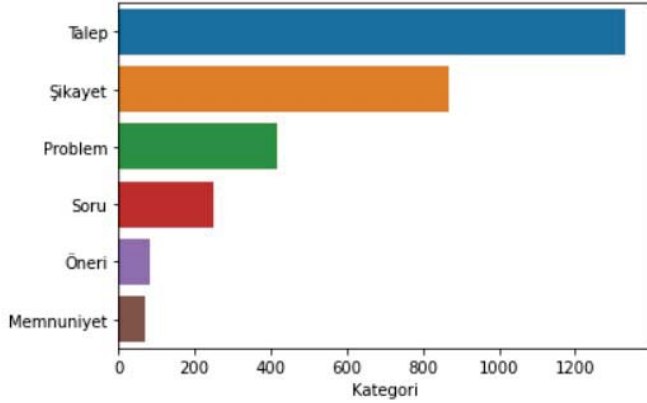
3. Yöntem

Bu çalışmada kaynak taramasında incelenen çalışmalarda en yüksek doğruluk değerlerinin elde edildiği Lojistik Regresyon, LSTM, Multinomial Naive Bayes ve SVM algoritmalarına odaklanılmıştır. Veri setini sınıflandırmak için detaylı olarak incelenmiş ve altı sınıfa ayrılması gerektiğine karar verilmiştir. Uygulanan metodoloji Şekil 1'de gösterilmektedir.



Şekil-1: Yöntem

Her sınıf için veri miktarı Şekil 2'de gösterilmiştir.



Şekil-2: Veri Setinin Kategorileri

Veri kümesini sınıflarken ederken müşterinin bankadan aldığı hizmetlerde sorun olduğunu düşündüren metinler "Problem" olarak etiketlendi. Müşterinin bankadan herhangi bir konuda talepte bulunduğunu düşündüren metinler "Talep", bankaya iletilmiş olan tüm sorular "Soru" olarak etiketlendi. Veri setinde bankaya gönderilen teklifleri ve banka hizmetlerinin kullanımına ilişkin öneriler (örneğin bankamatik yeri önerisi) "Öneri" olarak etiketlendi. Müşterinin beyanına göre; Tehdit, personelin tutumundan memnuniyetsizlik ve müşteri tarafından mağdur oldukları belirtilmiş ifadeler "Şikâyet" olarak etiketlendi. Son olarak müşterilerden gelen memnuniyet beyanı olduğu düşünülen metinler "Memnuniyet" olarak etiketlendi.

3.1. İşlem Adımları

Veri kümesini gerçek bir banka müşterilerinin farklı kanallardan bankaya ilettiği 6 aylık verilerden oluşmaktadır. 3020 kayıttan oluşan bu veri banka operatörleri tarafından kişisel veri içermeyecek şekilde maskelenmiştir. Veri seti,

halka açık bir veri kümesini olmayıp ticari kaygılar nedeniyle paylaşamaz. Veri müşterilerden gelme tarihine göre sıralanmaktadır.

Veri kümesini tarihe göre artan sırada olduğundan, benzer bir zamanda meydana gelen olaylar için yanılmayı en aza indirmek amacıyla karıştırıldı. Dilsiz sözcükler, belirli bir anlamı olmayan ancak sözcükleri birbirine bağlamak için kullanılan sözcükleri ifade eder. İlk olarak, tek başına bir anlam ifade etmeyen sözcükler veri kümesinden çıkarıldı. Veri kümesinden çıkarılacak dilsiz sözcükler için python programlama dilindeki Doğal Dil İşleme Araç Kiti (NLTK) kütüphanesi kullanıldı. Ardından, metindeki sözcüklerde kullanılan büyük harfler küçük harfe dönüştürüldü ve noktalama işaretleri kaldırıldı. Son olarak metindeki her sözcüğün metinde geçme sayısı (sıklığı) bulundu ve BoW oluşturuldu. Oluşturulan BoW yardımıyla her sözcük eşsiz olacak şekilde kodlanarak sayısal değerlere dönüştürüldü. Bu kodlama eğitim adımında uygulandı.

Tüm algoritmalar aynı eğitim ve sınav verileriyle çalışacak şekilde kodlandı. Veri kümesinin başlangıcından itibaren her bir algoritma için %70'i eğitim verisi ve kalan %30'u sınav verisi olacak şekilde belirlendi. Her algoritma için eğitim işlemi gerçekleştirildikten sonra elde edilen sonuç %30'luk sınav verisi üzerinde denendi edildi.

4. Sonuç

Kaynak taramasında NLP'de başarılı sonuçlar ürettiği fark edilen algoritmalar (Çizelge 1'de "Algoritma" başlığı altında gösterilmektedir) kullanılarak 6 ayrı sınıfa ayrılmış veri kümesini "3.1. İşlem Adımları" başlığı altında ifade edilen yöntemlerle sınıflandırarak yapılan çalışmada elde edilen sonuçlar Çizelge 1'de Temel Yöntem sütununda her bir algoritma için gösterilmiştir.


Çizelge-1: Deneysel Sonuçları

Algoritma	Doğruluk		
	Temel Yöntem	Önerilen Yöntem	
		İlk Aşama	İkinci Aşama
Logistic Regression	%61,47	%77,26	%72,45
LSTM	%39,07	%65,89	%66,44
Multinomial Naive Bayes	%55,18	%69,20	%67,94
SVM	%62,36	%74,83	%71,45

%39-%63 bandında doğruluk elde edilen bu sonuçlar, iki tahminden neredeyse birinin başarısız olduğu düşünüldüğünde başarısız olmuştur. Ancak Türkçenin sondan eklemeli bir dil olması ve sözcüklerin kök ve eklerinin ayrıştırılmaması nedeniyle bu doğruluk düşük olmuş olabilir.

Buna göre Şekil 1'deki gibi bir model geliştirildi. Problem, Talep, Soru sınıfında bankaların önem verdiği ve tazmin edilmesi muhtemel olan, finansal kayıp riskine neden olabilecek mesajlar genellikle bu sınıftaki veriler olduğundan bu verilerin ayrıştırılması esastır. Bu nedenle önerilen

yaklaşım; bu üç gruba ait veri kümesi bir sınıf olarak, geriye kalan Şikâyet, Memnuniyet, Öneri sınıfına ait veriler ayrı bir sınıf olarak bölündükten sonra ön işleme adımı gerçekleştirildi. Son olarak veri kümesi eğitim ve sınav aşamasından geçirildi. Lojistik regresyon algoritması kullanılarak sınav verisi üzerinde elde edilen sonuçlar Şekil 3'teki gibidir.




Şekil-3: İlk Aşamada Lojistik Regresyon algoritmasıyla elde edilen Karışıklık Matrisi

Multinomial Naive Bayes algoritması ile sınav verileri üzerinde elde edilen sonuçlar Şekil 4'te gösterilmektedir.



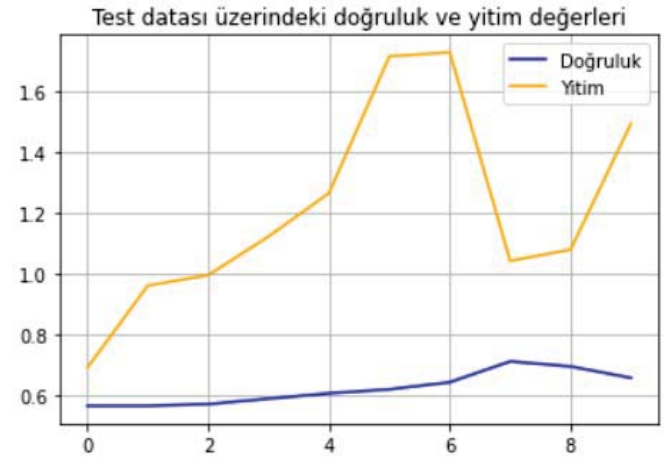
Şekil-4: İlk Aşamada Multinomial Naive Bayes Algoritmasıyla elde edilen Karışıklık Matrisi

SVM algoritması ile sınav verileri üzerinde elde edilen sonuçlar Şekil 5'te gösterilmektedir.




Şekil-5: İlk Aşamada SVM Algoritmasıyla elde edilen Karışıklık Matrisi

LSTM algoritmasının kullan çalışmada, eğitim verisiyle 10 kez yapılan eğitim sonucunda %99,43 doğruluk elde edildi. Sınav verisiyle 10 kez (epoch) yapılan eğitim sonucunda her bir adımda elde edilen sonuçlar Şekil 6'da, oluşan karışıklık matrisi Şekil 7'de gösterilmektedir.



Şekil-6: İlk Aşamada LSTM algoritmasıyla elde edilen Doğruluk Grafiği




Şekil-7: İlk Aşamada LSTM algoritmasıyla elde edilen Karışıklık Matrisi

Bu adım her bir algoritma için uygulandıktan sonra ikinci aşamada Problem, Talep, Soru olarak etiketlenen satırlardan


oluşan veri kümesinin %70'i eğitim, %30'u sınamaya verisi olarak ayrıştırılıp eğitim ve sınamaya adımları uygulandı.

Lojistik Regresyon algoritması ile elde edilen sonuçlar Şekil 8'de gösterilmektedir.




Şekil-8: İkinci Aşamada Lojistik Regresyon Algoritmasıyla elde edilen Karışıklık Matrisi

Multinomial Naive Bayes algoritması ile sınamaya verisi üzerinde elde edilen sonuçlar Şekil 9'da gösterilmektedir.




Şekil-9: İkinci Aşamada Multinomial Naive Bayes Algoritmasıyla elde edilen Karışıklık Matrisi

SVM algoritması ile sınamaya verisi üzerinde elde edilen sonuçlar Şekil 10'da gösterilmektedir.




Şekil-10: İkinci Aşamada SVM Algoritmasıyla elde edilen Karışıklık Matrisi

LSTM algoritması kullanarak yapılan bu çalışmada, Eğitim kümesi 10 kez (epoch) eğitimden geçirilerek %80,21 doğruluk değeri ölçüldü. Sınamaya verilerinin eğitimi sonucunda her bir adımda elde edilen doğruluk değeri Şekil 11'de, oluşan karışıklık matrisi Şekil-12'de gösterilmiştir.



Şekil-11: İkinci Aşamada LSTM Algoritmasıyla elde edilen Doğruluk Grafiği



Şekil-12: İkinci Aşamada LSTM Algoritmasıyla elde edilen Karışıklık Matrisi

Literatür taramasına göre metin sınıflandırmada başarılı sonuçlar elde edilmiş olan Lojistik Regresyon, Multinomial Naive Bayes, LSTM ve SVM algoritmaları kullanılarak gerçek

bir banka veri kümesi üzerinde yapılan bu çalışmadan elde edilen sonuçlar Çizelge 1'de gösterilmektedir. "Temel Yöntem" sütunundaki değerler, uygun görülen sınıf sayısına göre Çizelge 1'de "Algoritma" sütununda belirtilen algoritmalar uygulandıktan sonra sınıflandırma verisi üzerinde elde edilen doğruluk değerlerini ifade eder. Bu çalışmada geliştirilen yöntem, iki aşamalı yaklaşımla iki ayrı sınıflandırmayla elde edilen sınıflandırma sonuçlarının, tek aşamalı yaklaşımla bir kez yapılan sınıflandırma yapılarak elde edilen sonuçlara (Çizelge 1'de "Temel Yöntem" sütununda gösterilen sonuçlar) kıyasla uygulamanın performansının yaklaşık yüzde onun üzerinde artırdığı gözlemlendi. "Önerilen Yöntem" başlığının altındaki "İlk Aşama" sütununda gösterilen veriler 2 sınıfa ayrılmış veri setinin eğitim ve sınıflandırma aşamasından sonra elde edilen doğruluk değerlerini gösterir. Aynı başlığın altındaki "İkinci Aşama" sütununda gösterilen veriler banka için önem arz eden verilerin olduğu 3 sınıfa ayrılmış verilerin eğitim ve sınıflandırma aşamasından geçmesiyle elde edilen doğruluk değerlerini ifade eder. Bu çalışmada sınıf sayısı artırılmış, sınıflandırma iki aşamalı yaklaşımla yapılmış, sınıflara öncelik verilerek müşteriye hızlı bir şekilde ulaştırılması ve operatörlerin yapması gereken işlerin makineye aktarılması hedeflenmiştir.

5. Değerlendirme

Bu çalışmada, banka müşterilerinin talep, istek ve sorularını öncelikli olarak sınıflandırılması amaçlanmıştır. Böylece müşteri talep, istek ve sorularına öncelik verilerek cevap verilmesi hedeflenmiştir. Böylelikle müşteri memnuniyeti sağlanmaya çalışılır. Sonuçlar, iki aşamalı yaklaşımın sınıflandırma sonucunun, tek aşamalı yaklaşımın sınıflandırma sonucundan ortalama olarak yüzde onun üstünde daha başarılı olduğunu göstermektedir. Bu yaklaşımla sınıflandırma, doğruluğu artıracak şekilde iki adımda gerçekleştirilir. Türkçe sondan eklemeli bir dil olduğu için ne yazık ki veri setindeki sözcüklerin kökü bulunup eklerinden ayrıştırılamamıştır. Bu nedenle sunulan yöntemle doğruluk oranı artırılmış olsa da çalışmanın başarı oranı daha fazla yükseltilememiştir. Yine de sınırlı sayıda veri seti ile çalışılarak bu sonuca ulaşılmıştır.

İleride yapılacak çalışmalarda her sözcüğün kökü bulunup, sözcüklerdeki ekleri kaldırarak daha fazla veri ile daha yüksek performans elde edilebilir. Veri seti ve sınıflar kullanılarak KPI'lar belirlenir ve müşteri memnuniyeti için elde edilen müşteri puanı kullanılabilir. Altı farklı sınıflandırmaya ek olarak, veri seti mevcut banka müşterilerini bankanın belirlediği herhangi bir standarda ve müşterilerin sahip olacakları müşteri puanına göre sıralanacak şekilde düzenlenebilir. Böylece banka, puanı yüksek olan müşterileri belirlediği standarda göre sıralayabilir ve bu sırayla müşterilere geri dönebilir. Bu öneri bankalar için avantajlı gibi görünse de banka müşterilerini belirli kurallara göre sıralayacağından düşük puanlı müşterileri memnun etmeyecektir.

6. Kod Paylaşımı

Çalışma sonuçlarının elde edilmesi için kullanılan kodlar <https://github.com/makgumus/NLP> adresinde açık olarak verilmiştir.

Kaynakça

- [1] Hakiri W., "For an efficient complaints management system for banks: A conceptual framework and an exploratory study," *Journal of Marketing Research & Case Studies*, vol. 2012, p. 1, 2012
- [2] Salim A., Setiawan M., Rofiaty R., Rohman F. Ve ark., "Focusing on complaints handling for customer satisfaction and loyalty: The case of Indonesian public banking," *European Research Studies Journal*, vol. 21, no. 3, pp. 404–416, 2018
- [3] Lu X., Yang Y., ve Qin H., "The research on personal internet banking service quality and customer loyalty based on complaints handling," in *2010 International Conference on Management and Service Science*. IEEE, 2010, pp. 1–4
- [4] Eser Z., Pınar M., ve Girard T., "Importance of customer complaints: A study of banking industry utilizing the services marketing and branding triangle framework," *Journal of Theory and Practice in Marketing*, vol. 2, no. 2, pp. 23–49, 2016.
- [5] Harkiranpal S., "The importance of customer satisfaction in relation to customer loyalty and retention," *Asia Pacific University*, 2006.
- [6] Ibrahim A., Pratiwi A., Meytri D. I., Kurniawan M. A., Yuniarti N. Ve ark., "Measuring customer satisfaction using crm scorecard in canteen fasikom unsri," in *2018 International Conference on Electrical Engineering and Computer Science (ICECOS)*. IEEE, 2018, pp. 403–408.
- [7] Gong S., Dai Y., Ji J., Wang J., ve Sun H., "Emotion analysis of telephone complaints from customer based on affective computing," *Computational intelligence and neuroscience*, vol. 2015, 2015.
- [8] Corpuz R. S. A., "Categorizing natural language-based customer satisfaction: an implementation method using support vector machine and long short-term memory neural network," *International Journal of Integrated Engineering*, vol. 13, no. 4, pp. 77–91, 2021.
- [9] Corpuz R. S. A., "An application method of long short-term memory neural network in classifying English and Tagalog-based customer complaints, feedbacks, and commendations," *International Journal on Information Technologies and Security*, vol. 13, no. 1, p. 2021, 2021.
- [10] Laksono R. A., Sungkono K. R., Sarno R., ve Wahyuni C. S., "Sentiment analysis of restaurant customer reviews on TripAdvisor using Naïve Bayes," in *2019 12th International Conference on Information & Communication Technology and System (ICTS)*. IEEE, 2019, pp. 49–54.
- [11] Harris Z. S., "Distributional structure," *Word*, vol. 10, no. 2-3, pp. 146–162, 1954.
- [12] Qader W. A., Ameen M. M., ve Ahmed B. I., "An overview of bag of words; importance, implementation, applications, and challenges," in *2019 International Engineering Conference (IEC)*. IEEE, 2019, pp. 200–204.
- [13] Kumar A., Dhanalakshmi V., Rekha R., Soman K., Rajendran S. ve ark., "Morphological analyzer for agglutinative languages using machine learning approaches," in *2009 International Conference on Advances in Recent Technologies in Communication and Computing*. IEEE, 2009, pp. 433–435.
- [14] Kintz M., Dukino C., Blohm M., ve Hanussek M., "Make your customers happy again: AI and NLP for a customer complaint management platform," 2020.
- [15] Yıldırım E., Çetin F. S., Eryiğit G., ve Temel T., "The impact of NLP on Turkish sentiment analysis," *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, vol. 7, no. 1, pp. 43–51, 2015.

- [16] Gavval R., Ravi V., Harshal K. R., Gangwar A., ve Ravi K., "Cuda-self organizing feature map based visual sentiment analysis of bank customer complaints for analytical crm," arXiv preprint arXiv:1905.09598, 2019.
- [17] Gupta D., Lenka P., Bedi H., A. Ekbal, and P. Bhattacharyya, "Auto analysis of customer feedback using cnn and gru network," arXiv preprint arXiv:1710.04600, 2017.
- [18] Hosmer Jr D. W., Lemeshow S., ve Sturdivant R. X., Applied logistic regression. John Wiley & Sons, 2013, vol. 398.
- [19] Setyawan M. Y. H., Awangga R. M., ve Efendi S. R., "Comparison of multinomial naive bayes algorithm and logistic regression for intent classification in chatbot," in 2018 International Conference on Applied Engineering (ICAE). IEEE, 2018, pp. 1–5.
- [20] Hochreiter S. ve Schmidhuber J., "Long short-term memory," Neural computation, vol. 9, no. 8, pp. 1735–1780, 1997.
- [21] Bai X., "Text classification based on lstm and attention," in 2018 Thirteenth International Conference on Digital Information Management (ICDIM). IEEE, 2018, pp. 29–32.
- [22] Singh G., Kumar B., L. Gaur, and A. Tyagi, "Comparison between multinomial and bernoulli naive bayes for text classification," in 2019 International Conference on Automation, Computational and Technology Management (ICACTM). IEEE, 2019, pp. 593–596.
- [23] Cortes C. ve Vapnik V., "Support-vector networks," Machine learning, vol. 20, no. 3, pp. 273–297, 1995.
- [24] Liu Z., Lv X., Liu K., ve Shi S., "Study on svm compared with the other text classification methods," in 2010 Second international workshop on education technology and computer science, vol. 1. IEEE, 2010, pp. 219-222.