

PAPER DETAILS

TITLE: Türkçe Kısa Mesajları Sınıflandıran Çok Katmanlı Süzgeçleme Mimarisi ve Akıllı SMS Kutusu

AUTHORS: H İbrahim BESTİL, M Amaç GÜVENSAN

PAGES: 17-28

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/693924>

Türkçe Kısa Mesajları Sınıflandıran Çok Katmanlı Süzgeçleme Mimarisi ve Akıllı SMS Kutusu

A Novel Multi-tier Filtering Architecture and Smart SMS Box for Classification of Turkish Short Messages

Halil İbrahim BESTİL¹ , M. Amaç GÜVENSAN¹ 

¹Yıldız Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Bilgisayar Mühendisliği Bölümü, 34220, Esenler / İstanbul

Öz

Kısa mesaj servisi en yaygın kullanılan iletişim kanallarından biridir. Kişisel, reklam, promosyon, etkinlik bildirimi, satış onaylama vb. birçok farklı amaç için kullanılan kısa mesajların sayısının her geçen gün artması takip edilebilirliklerini ve aranan mesajın mesaj kutusunda hızlıca bulunmasını zorlaştırmaktadır. Öte yandan istenmeyen mesajların mesaj kutusunu doldurması ve mesaj kirliliği yaratması bir diğer önemli problemdir. Bu çalışmada Türkçe Kısa Mesajları sınıflandırmak ve akıllı bir SMS kutusu oluşturmak amacıyla Çok Katmanlı Süzgeçleme Mimarisi önerilmiştir. Ayrıca bu mimari bir Android uygulaması üzerinde gerçekleştirilmiştir. Bu mimari yardımı ile telefona ulaşan mesajlar *kişisel*, *ticari*, *otp kodları*, *hatırlatıcı* ve *istenmeyen* adı altında 5 farklı kategoriye ayrılmaktadır. Önerilen mimari Kara Liste, Regex, Makine öğrenmesi ve Beyaz Liste süzgeçlerinden oluşmaktadır. Makine öğrenmesi süzgecinde Naive Bayes, Bayes Net, J48 ve Random Forest algoritmalarının performansları incelenmiştir ve Random Forest %87'lik başarıları nedeniyle uygulamada tercih edilmiştir. Önerilen çok katmanlı yapı sayesinde mesaj sınıflandırma süresi azaltılırken sınıflandırma başarıları %93'e yükseltilmiştir. Ayrıca başarının yükseltilmesinde seçilen özellikler ve Zemberek kütüphanesinin kullanımı ile kelimelerin türlerinin ve köklerinin elde edilmesi önemli rol oynamıştır.

Anahtar Kelimeler: Türkçe SMS Sınıflandırma, Çok Katmanlı Süzgeçleme Mimarisi, Mobil Uygulama, Kara ve Beyaz Liste, Kurallı İfadeler, Makine Öğrenmesi

Abstract

The short message service is one of the most commonly used communication channels. Increasing number of short messages that are used for many different purposes including personal, advertising, promotion, event notification, sales approval, etc. makes it difficult to keep track of messages and to find the target message quickly in the message box. On the other hand, another important problem is the spam messages filling the message box unnecessarily. In this study, a novel Multi-tier Filtering Architecture is proposed to classify Turkish Short Messages and to create a smart SMS box. This architecture is also implemented on an Android application. Received messages and old messages are divided into 5 different categories under *personal*, *commercial*, *otp codes*, *reminders* and *spam messages* with the help of the proposed architecture. This architecture consists of 4 tiers including Black List, Regex, Machine Learning, and White List filters. The performance of Naive Bayes, Bayes Net, J48 and Random Forest algorithms were examined and Random Forest was preferred for mobile application due to its success of 87%. Thanks to the proposed multi-tier system architecture, the classification success rate has been increased to 93% while the message classification time is reduced. In addition, the selected features, the use of the Zemberek library and the acquisition of the types and roots of the words within the message played an important role in the promotion of success.

Keywords: Turkish SMS Messages, Classification, Multi-tier Filtering Architecture, Mobile Application, Black and White List, Regex, Machine Learning

I. GİRİŞ

Mobil haberleşmede en yaygın kullanılan iletişim biçimlerinden bir tanesi kısa mesaj servsidir (SMS – Short Message Service). SMS mesajlarının kullanımının yaygınlaşması mesajların niteliklerini ve tiplerini arttırmıştır. Günümüzde SMS kişisel mesajlaşmaların yanı sıra; pazarlama, mobil doğrulama, kargo takip hizmetleri ve bankacılık işlemleri gibi birçok alanda kullanılmaktadır.

Kısa mesaj servisi ucuz ve kullanımı kolay olması sebebi ile duyuru, reklam, promosyon gibi ticari içeriklerin dağıtılmasında kullanılan yöntemlerin başında gelmektedir. Telefon numaraları kişiye mahsus ve benzersiz olduğu için firmalar güvenlik ve doğrulama kodlarını SMS olarak göndermektedir. Toplantı, uçuş vb. birçok etkinliği organize eden şirketler bilet örneklerini kullanıcılara SMS yoluyla ulaştırmaktadır. Aynı zamanda kurumlar yaklaşan etkinliklerini kısa mesajlar ile kullanıcılarına hatırlatmaktadır. SMS gelen kutusuna düşen farklı nitelikteki mesaj sayısının artması, kullanıcının mesajlarını takip etmesini ve yönetmesini gün geçtikçe zorlaştırmaktadır.

Günümüz yaşam şartlarında zamanın etkin ve verimli kullanılması kaçınılmaz hale gelmiştir. İnsanlar zamanı etkin kullanmaya gayret etmekte, zamandan tasarruf edebilecekleri hizmetleri talep etmekte ve bu hizmetlere para harcamaktadır. Örneğin e-posta araçlarından Gmail ve Outlook; e-postaları sosyal, önemsiz, tanıtım gibi başlıklar altında sınıflandırarak elektronik postaların kullanım ve erişim kolaylığını arttırmaktadır. E-postalar gibi SMS’lerin de kategoriler altında sınıflandırılması, SMS hizmetini kullananlar için kolaylık ve zaman tasarrufu sağlayacaktır.

Literatürde yapılan çalışmalar incelendiğinde, mesajları ve e-postaları sınıflandırma işleminin çeşitli makine öğrenmesi algoritmaları ve doğal dil işleme yöntemleri kullanılarak oluşturulan tek veya çok katmanlı mimariler ile sağlandığı gözlenmektedir. Literatürde, e-postaların farklı kategoriler altında sınıflandırılması probleminin çözümü için çok sayıda çalışma [1,2] bulunmasına rağmen, kısa mesajların sınıflandırılmasına yönelik problem için yapılan çalışmalar sınırlı sayıdadır.

Kısa mesajların sınıflandırılması hakkında Healy, Matt [3] ve arkadaşlarının yaptıkları çalışmada Destek Vektör Makineleri ve Naive Bayes sınıflandırıcılar kullanılarak karar tabanlı sınıflandırıcılar oluşturulmuştur. Najadat [4] ve Joe [5] yaptıkları çalışmalarda kısa mesaj gövdelerinden oluşturdukları sözcük vektörlerine göre kısa mesajları sınıflandırmışlardır. Mahmoud ve Ahmet [6] oluşturdukları yapay bağışıklık sistemi ile istenmeyen (spam) kısa mesaj olan ve olmayan mesajları sınıflandırmışlardır. Deepshikha ve Monika [7] yapay sinir ağları yardımı ile kısa mesajları önceden belirlenmiş

şaka, festival ve istenmeyen gibi kategorilere ayırmışlardır. Ghayda ve Hind [8] vektör uzay modeli ve TF-IDF tekniğini temel alarak kısa mesajları önceden belirlenmiş kategoriler (durumlar, tebrik, arkadaşlık ve satış) altında sınıflandırmışlardır. Parimala [9] yaptığı çalışmada doküman frekans eşik değerini ve Destek Vektör Makinelerini kullanarak sınıflandırma işlemini gerçekleştirmiştir. Deng vd. [10] tarafından yapılan çalışmada, Naive Bayes sınıflandırıcısı kullanarak kullanıcı cihazında sınıflandırma yapılmasını sağlamıştır. Geliştirdikleri sistem kullanıcının girdilerine göre kendi-kendini eğitmekte ve bu sayede eğitim verileri sürekli güncel tutulmaktadır. Dipak [11], çalışmasında J48, Naive Bayes gibi farklı algoritmaları karşılaştırarak istenmeyen kısa mesajları filtrelemiştir. Kuruvilla [12] yaptığı çalışmada popüler istenmeyen mesaj filtreleme tekniklerini karşılaştırmalı olarak incelemiştir. Bahsedilen çalışmalarda kullanılan veri setleri ve çıkartılan özellikler İngilizce içerikli mesajların sınıflandırılmasına yönelik uygulamalardır. Türkçe yapılan çalışmalarda da İngilizce için kullanılanlara benzer teknikler kullanılmıştır ancak dillerin farklı olması sebebiyle metinlerden çıkartılan özellikler değişmiştir. Uysal ve arkadaşlarının [13] yaptığı çalışmada Türkçe kısa mesajları içeriklerine göre etkin öznelik seçme ve örüntü sınıflandırma yöntemlerini kullanan bir süzgeç geliştirilmiştir. Esma vd. [14] kara liste, beyaz liste ve anlamsal/biçimsel özellikler katmanlarından oluşan üç katmanlı hibrit mesaj filtreleme mimarisi ile istenmeyen ve normal mesajları birbirinden ayıran sınıflandırma işlemini gerçekleştirmişlerdir.

Bu çalışmada, bahsedilen diğer çalışmalardan farklı olarak, hem beyaz liste/kara liste yaklaşımını hem tarih/otp (Tek Kullanımlık Şifre – One Time Password) kodları ön-süzgeçlerini içeren hem de kısa mesaj içeriklerini biçimsel ve anlamsal yönleri ile değerlendirerek sınıflandırmayı gerçekleştiren bir mimari önerilmektedir. Önceki çalışmalarda mesajlar genellikle “istenmeyen” ve “normal” olarak iki sınıfa ayrılırken, bu çalışmada kısa mesajlar *kişisel*, *hatırlatıcı*, *ticari*, *otp kodları* ve *istenmeyen* olmak üzere toplamda beş kategori altında sınıflandırılmaktadır. Ön süzgeçlerin oluşturulmasında tarih ve otp kodlarını algılayan Regex’ler (kurallı ifadeler) kullanılmaktadır. Beyaz/kara liste ve ön süzgeçlerin kullanılmasıyla makine öğrenmesi modeline iletilen SMS sayısı azaltılmıştır. Kara listede bulunan numaralardan gelen veya gövdesinde kara listede bulunan kelimeleri bulunduran kısa mesajlar sınıflandırma filtresine gönderilmeden “*istenmeyen*” mesaj olarak değerlendirilmektedir. Aynı şekilde bahsedilen ön-süzgeçler yardımı ile içerisinde zaman ifadesi içeren mesajlar “*hatırlatıcı*”, otp kodu bulunduran kısa mesajlar “*otp*” olarak değerlendirilmektedir.

Mesajların biçimsel ve anlamsal özelliklerine göre sınıflandırılmasında *Naive Bayes*, *Bayes Net*, *J48* ve *Random*

Forest algoritmalarının performansları incelenmiştir. Analizler sonucunda başarıyı en yüksek *Random Forest* sınıflandırma yöntemi tercih edilerek kısa mesajları sınıflandıran bir Android mobil uygulaması geliştirilmiştir.

Önerilen sistem mimarisi Şekil 1’de ifade edilmiştir. Şekil 1’de sarı ile çevrelenmiş alan çok katmanlı süzgeçleme mimarisinin sınırlarını ifade etmektedir. Çok katmanlı süzgeçleme mimarisine ulaşan kısa mesajlar filtrelenerek ait olduğu sınıfa karar verilmektedir. Elde edilen sınıf bilgisi ile birlikte kısa mesaj uygulama veri tabanına kaydedilerek uygulama arayüzünde listelenmeye hazır hale gelmektedir.

“Çok katmanlı Süzgeçleme Mimarisi” başlığında çok katmanlı sınıflandırma mimarisinden ve alt başlıklar halinde mimarinin süzgeçleme katmanlarından bahsedilmiştir. “Uygulama” başlığı ile tasarlanan mimarinin Android ortamında gerçekleşmesi ile geliştirilmiş uygulama genel hatlarıyla tanıtılmıştır. “Performans Analizi” kısmında adım adım yapılan çalışmaların sonuçlara etkisi irdelenmiştir. “Uygulama Metrikleri” bölümünde sistemin genel performansının karşılaştırmalı analizine yer verilmiştir. “Sonuç” bölümünde elde edilen çıktılar yorumlanmış, sistem genel hatlarıyla özetlenmiştir.

II. Çok Katmanlı Süzgeçleme Mimarisi

Önerilen çok katmanlı mesaj süzgeçleme mimarisi ile cihaza ulaşan mesaj dört farklı süzgeçten geçirilmektedir. Süzgeçleme mimarisine giren kısa mesajın önce kara listede olup olmadığı kontrol edilmektedir. Eğer kısa mesajın göndereni veya mesaj içeriğindeki bir kelime kara liste içerisinde bulunuyorsa mesaj “istenmeyen” olarak etiketlenmektedir.


Bu aşamayı geçen kısa mesaj henüz etiketlenmemiş ise mesaj içerisinde OTP kodları ve tarihler ile eşleşen Regex’lerin bulunduğu diğer bir filtreye tabii tutulur. Eğer mesaj içeriğinde Regex’ler ile bir eşleşme varsa mesaj ilgili olduğu Regex’in sınıfıyla, “otp” veya “hatırlatıcı”, olarak etiketlenmektedir.

Önceki iki süzgece de takılmadan ilerleyebilmiş bir kısa mesaj var ise mesajın sınıf bilgisi *Random Forest* algoritması ile oluşturulmuş sınıflandırma modeli çalıştırılarak elde edilmektedir. Beyaz liste yaklaşımı da modelin çalışmasının ardından devreye girmektedir. Belirlenmiş koşullara uygunluk durumunu değerlendiren bu yaklaşıma ilerleyen paragraflarda değinilmiştir. Çok katmanlı süzgeçleme sayesinde sınıflandırma algoritmasının çalıştırılma sayısı azaltılmıştır. Önerilen çok katmanlı süzgeç mimarisinde kullanılan algoritmanın akış diyagramı Şekil 2’de ifade edilmiştir.


2.1 Kara Liste Süzgeci

Ön süzgeçleme yöntemlerinden biri olan kara ve beyaz liste yöntemi anahtar kelime bazlı filtreleme uygulamalarında sıkça kullanılan yöntemlerden biridir. Bu yöntemde kullanıcı, beyaz (güvenli) ve kara (istenmeyen) olarak tanımlanan iki sınıf için kelime listelerini oluşturur.

Herhangi bir metin kara liste süzgecinden geçirilmek istendiğinde metnin içerdiği tüm kelimeler “kara liste” elemanları ile karşılaştırılır, eğer metin kara liste elemanlarından birini ya da birkaçını içeriyorsa “kara liste” süzgeci pozitif çıktı üretir. Negatif çıktı ise metin içerisinde herhangi bir kara liste elemanının bulunmaması sonucunda üretilir.



Şekil 1. Sistem Mimarisi



Şekil 2. Süzgeçleme Mimarisinin Akış Diyagramı

2.2 Regex ile OTP ve Hatırlatıcı Süzgeci

Metin içerisinde belirli bir dizilimde bulunan ancak içerikleri farklı olabilen birtakım kelimeler bulunabilir. Örneğin tarihler zaman dilimi ifade edebilir ancak sunumları 24.03.1997 ya da 11/04/2024 gibi farklı şekillerde olabilir. Benzer problemler ile SMS sınıflandırma sürecinde karşılaşılmaktadır. Bankaların onay kodları, kargo takip numaraları ve tarih hatırlatıcıları gibi formatı aynı ancak içeriği farklı olan SMS'lerin sınıflandırılması "Regex"ler yardımı ile hızlı bir şekilde yapılabilir.

Regex'ler metin içerisinden belli kurallara uyan alt metinler elde etmek için kullandığımız bir yöntemdir. Metin içerisinde geçen yararlı özellik niteliğindeki düzenli alt metinlerin sınıflandırma modeli çalıştırılmadan süzgeçlenmesi sistem performansına olumlu katkı sağlayacaktır. Bu sebeple sistem mimarisine ara katman olarak Regex temelli "hatırlatıcı" ve "otp kodları" süzgeçleri eklenmiştir.

"Hatırlatıcı" Regex'i ile tarih ifade eden mesajlar süzgeçlenerek "hatırlatıcı" sınıfında uygulama veri tabanına kaydedilmektedir. Benzer şekilde "otp kodu" Regex formatları ile eşleşen bir kısa mesaj ile karşılaşıldığında mesajın sınıfı "otp kodu" olarak etiketlenmektedir. Tarih yazımlarındaki 24.03.2018, 24/03/2018 gibi farklılıklar, otp kodlarındaki biçimsel farklılıklar göz önünde bulundurularak her süzgeç için sık kullanılan formatlar incelenmiş ve


tespit edilen formatlar ile eşleşen Regex'ler geliştirilip sisteme entegre edilmiştir.

2.3 Kısa Mesajların Makine Öğrenmesi Yöntemleri ile Sınıflandırılması

Mesajların farklı kategoriler altında sınıflandırılarak organize edilmesi bir metin sınıflandırma problemidir. Sistem girdi olarak SMS mesajı almakta ve mesajın etiket bilgisini "kişisel", "ticari", "hatırlatıcı", "otp kodları" ve "istenmeyen" olarak tespit etmektedir.

Çok katmanlı bir sınıflandırma mimarisinin gerçekleştirilmesi için, veri setinin toparlanması, ön işlemlerden geçirilmesi ve özellik çıkarımı gibi izlenmesi gereken adımlar bulunmaktadır. Önerilen çok katmanlı sınıflandırma mimarisini gerçeklerken Şekil 3'te ifade edilen yol haritası izlenmiştir.

Gönüllü kısa mesaj sağlayıcılardan elde edilen mesajlar ayıklama, özellik seçimi gibi ön işleme aşamalarına tabii tutulmuş, ardından algoritmaların veri seti üzerindeki başarımlarını ölçebilmek için çeşitli testler gerçekleştirilmiştir. Yapılan testler sonucunda en güvenilir algoritma belirlenmiş ve model çıktısı alınmıştır. Sonuçların gerçek zamanlı ölçülebilmesi ve sınıflandırma modelini kullanıcıya ulaştırabilmek için bir Android uygulaması geliştirilmiştir.



Şekil 3. Sistemin Oluşturulması Sırasında İzlenen Temel Adımlar

2.3.1 Veri setinin oluşturulması

Metinlerin sınıflandırılabilmesi için eğitim ve test veri kümelerine ihtiyaç duyulmaktadır. Veri kümesini oluşturabilmek için 11 kişiden 2402 adet kısa mesaj toplanmıştır. Kişilerden çalışma kapsamında kısa mesajlarının alınmasına ve gerçekleştirilecek tüm akademik çalışmalarda kullanılmasına dair onay alınmıştır. Benzerlik gösteren veya aynı kısa mesajlar elenerek mesaj sayısı 1780'e düşürülmüştür. Ardından mesajlar incelenerek önceden belirlenmiş “*kişisel*”, “*ticari*”, “*hatırlatıcı*”, “*otp kodları*” ve “*istenmeyen*” etiketleriyle etiketlenmiştir.

Tablo 1. Mesaj Sınıfları ve Bulundurdıkları Mesaj Miktarları

Mesaj Sınıfı	Miktar	%
Kişisel	839	47,13
Ticari	245	13,76
Otp Kodları	132	7,41
Hatırlatıcı	510	28,65
İstenmeyen	54	3,03

2.3.2 Örnek mesajlar

Mesaj tiplerinin öne çıkan karakteristik özellikleri bulunmaktadır. Örneğin “hatırlatıcı” tipindeki mesajlarda “bilet” ve “toplantı” kelimeleri çokça kullanılmakta, “ticari” tipteki mesajlarda ise “kampanya” ve “hediye” kelimeleri öne çıkmaktadır. Ayrıca biçimsel olarak incelendiğinde “istenmeyen” mesajların içeriğinde büyük harf oranının daha fazla olması gibi biçimsel-karakteristik özellikler de bulunmaktadır. Tablo 2’de her mesaj tipi için örnekler sunulmuştur. Sunulan örneklerde bazı şirket isimleri ve özel veriler değiştirilerek bilginin gizliliği sağlanmaya çalışılmıştır Bir sonraki

bölümde mesajların sınıflandırılabilmesi için yapılan özellik çıkarımı çalışmaları detaylandırılacaktır.

Tablo 2. Sınıflar için Örnek Mesajlar

Mesaj Sınıfı	Mesaj Gövdesi	Gönderen
Kişisel	Merhaba, nasılsın?	551.123.4567
Kişisel	Dün derste aldığın notların fotoğrafını gönderebilir misin?	A. Yiğit İlkadam
Hatırlatıcı	Merhaba Adem Bey, ABS filmine 24.03.2019 tarihine almış olduğunuz bilet onaylanmıştır. Keyifli seyirler dileriz. B125	BILETOMNIA
Hatırlatıcı	Merhaba Adem, Haftaya cuma (24/03/2020) tarihine düzenlediğimiz toplantıya katılman ekibimizi gururlandıracaktır.	Faruk Dağcı
Ticari	Süpper Kampanya!! Atikali Petrol- leri yapacağını 100TL ve üzeri alışverişlerinizde 20TL market harcaması hediye!	ATİKALİ PET- ROLLERİ
Ticari	Sana özel promosyon bu ay sonuna kadar yapacağın ilk 2 sürüş %20 indirimli. Ayrıntılı bilgi : ubr.com/flasdw	Uber
Otp Kodları	Değerli Müşterimiz, 24.03.2018 tarihinde yapmış olduğunuz 1223TL değerindeki alışverişinizi tamamlamanız için doğrulama kodunuz : A34sfS Keyifli alışverişler dileriz. B125	JETTOBANK
Otp Kodları	Satış Bilgileri : 09.02.2019 18:00 ISTANBUL-ESKİSEHIR YHT PNR No : S15 6QWE549 (65 TL) İyi yolculuklar dileriz... TCDD Taşımacılık A.Ş.	TCDD EYBIS
İstenmeyen	KAMPANYA!!! HEMEN AL, HA- YATINA SAĞLIK KAT! go.gl/as46dw58	554.859.9999
İstenmeyen	ANTALYADA DENİZE SIFIR LUX DAIRE VE YAZLIKLAR BU SE- ZONA OZEL %50 YE VARAN İNDİRİMLİ FİYATLARLA. KACIRMA- YIN : http://tinyurl.com/asdw1mm	ANTALYA BE- ACH

2.3.3 Özellik çıkarımı

Mesajların karakterini belirleyen mesajın göndereni, gönderim zamanı, büyük/küçük harf frekansı, kaç kelimeden oluştuğu vb. biçimsel birçok özellik bulunmaktadır. Aynı zamanda mesajın karakteristiğini belirleyen anlamsal özelliklerinin de göz önünde bulundurulması gereklidir. Anlamsal özelliklerin çıkarımı için Türkçe için geliştirilmiş doğal dil işleme kütüphanesi olan Zemberek kullanılmıştır. Zemberek yardımıyla cümle içerisindeki kelimelerin tipleri (*kelime*, *kısaltma*, *email*, *url* ve *tarih*) belirlenmiştir. Kelimeler köklerine ayrılarak “*kampanyalar*” ve “*kampanyası*” gibi kelimelerin aynı kelime olduğu algılanmaktadır. Tablo 4’te,

başlangıçta yapılan çalışmalar sonucu belirlenen özellikler ve tanımları bulunmaktadır.

Kısa mesaj içerisinde *URL*, *E-posta adresi*, *tarih* gibi içerik olarak farklı olan ancak ifade ettiği tip aynı olan simgeler (token) bulunabilir. Örneğin “;” (noktalı virgül) karakteri de bir noktalama işaretidir, “!” (ünlem işareti) de bir noktalama işaretidir. Kelime vektörlerini oluştururken “*” ve “!” gibi aynı tipteki simgelerin tip ismi ile kullanılması özellik seçiminde noktalama işaretlerinin sınıf belirlemedeki etkisini göstermesini sağlayacaktır.

Simgelerin yerine simge tiplerinin sonuçlara etkisini inceleyebilmek için yeni bir yaklaşım geliştirilmiştir. Bu yaklaşımda oluşturulacak “*roots*” özelliği için tipi “*kelime*” olan simgeler kelimenin kökü çıkarılarak, tipi “*kelime*” olmayan tüm simgeler ise simge tipi ile kaydedilmektedir. Örneğin “*Çantamda*” simgesi bir kelimedir, “*çanta*” olarak değerlendirilecektir. Ancak “*24.03.2019*” simgesi kelime değil, bir tarihtir. Dolayısıyla bu simge yerine simgenin tipi olan “*DATE*” yazılacaktır. Bahsedilen simge değerlendirme yaklaşımı Tablo 3’te örneklenmiştir.

Tablo 3. Simge Değerlendirme Yaklaşımı Örneği

Girdi (SMS Gövdesi)	Çıktı(Kökler)
”Kampanya 30.01.2018 tarihine kadar ‘B3SEW4’ kodu ile indirimli alışveriş şansı : http://www.abcd.com ”	”kampanya DATE tarih kadar WORDWITHAPOSTROPHE kod indirim alışveriş şansı URL”
“Merhaba, 07.05.2016* TARİHİNDE YAPTIGINIZ ALIŞVERİSTEN GALAXY ‘S5’ CEP TELEFONU KAZANDINIZ HEDİYENİZİ ALMAK İÇİN HEMEN ARAYIN 021.296.70098 B364”	“merhaba DATE PUNCTUATION tarih yap alışveriş galaxy WORDWITHAPOSTROPE cep telefon kazan hediye al için hemen ara NUMBER WORDWITHAPOSTROPE “

Her bir mesaj örneği için yukarıdaki özellik çıkarımlarının yapılmasının ardından WEKA kütüphanesinin sağladığı *StringToWordVector* filtresi yardımı ile yeni özelliklerin çıkarımında bulunulmuştur. *StringToWordVector* [15], *String* özniteliklerini, bir dizi metinden elde edilmiş özelliklere dönüştüren bir filtredir. Yeni özellikler filtrelenmiş sözcüklerden oluşmaktadır.

2.3.4 Sınıflandırma

Çalışma kapsamında *Naive Bayes*, *Bayes Net*, *J48* ve *Random Forest* algoritmaları veri seti üzerinde çalıştırılmış ve elde edilen sonuçlar kıyaslanmıştır. Sınıflandırma çalışması yapılırken özelliklerin sonuçlara etkisini incelemek için yeni özellikler eklenerek modeller tekrar test edilmiştir. Doğrulama yöntemi olarak *k katlamalı çapraz*

doğrulama (*k-fold cross validation*) kullanılmıştır ve yöntemdeki *k* değeri 10 olarak belirlenmiştir.

Naïve Bayes [16] bir sınıflandırma/kategorilendirme algoritmasıdır ve Bayes Teoremine dayanan bir sınıflandırma tekniğidir. Basit bir ifadeyle, bir Naive Bayes sınıflandırıcı, bir sınıftaki belirli bir özelliğin varlığının başka herhangi bir özelliğin varlığına bağlı olmadığını varsayar. Örneğin, bir meyve yeşil, yuvarlak ve çapı yaklaşık 10 cm ise bir karpuz olarak düşünülebilir. Bu özellikler birbirlerine veya diğer özelliklerin varlığına bağlı olsa bile, bu özelliklerin tümü, bu meyvenin bir karpuz olması olasılığına bağımsız olarak katkıda bulunur ve bu yüzden “Naif” olarak bilinir.

Bayes Net [17], veriden modeller oluşturmak için kullanılabilen bir olasılıksal grafik modeli türüdür. Tahmin, belirsizlik algılama, tanılama, otomatik iç gözü, akıl yürütme, zaman dizisi tahmini ve belirsizlik altında karar verme gibi çok çeşitli görevlerde kullanılabilirler. Bayes Net, bir dünyanın modellenen bir kısmının durumlarını yansıtır ve bu durumların olasılıklarla nasıl bağlantılı olduğunu anlatır. Örneğin, araba motoru normal çalışıyor veya sorun veriyor olabilir, vücudunuz hasta veya sağlıklı olabilir.

J48 [18][19], bir karar ağacı algoritmasıdır. Karar Ağacı algoritmaları, özniteliklerin – birtakım örnekler için davranış biçimlerini bulmayı sağlar. Bu algoritmalar, hedef değişkenin tahmin edilmesi için kurallar üretir. Ağaç sınıflandırma algoritması yardımıyla verilerin kritik dağılımı kolayca anlaşılabilir. C4.5 algoritmasının açık-kaynak JAVA gerçekleştirilen J48 algoritması ID3’ün bir uzantısıdır. J48 ek olarak eksik değerler, karar ağaçları budaması, sürekli öznitelik değer aralıkları, kuralların türetilmesi gibi birtakım özellikleri bulundurmaktadır.

Random Forest [20], hiper-parametrelili ayar yapmadan bile, çoğu zaman iyi bir sonuç üreten, esnek, kullanımı kolay bir makine öğrenmesi algoritmasıdır. Aynı zamanda en çok kullanılan algoritmalarından biridir, çünkü hem kullanımı kolaydır hem de sınıflandırma ve regresyon görevleri için kullanılabilir.

2.4 Beyaz Liste Süzgeci

Sistemin son katmanı olan “*Sınıflandırma Modeli*” katmanına yardımcı olarak tasarlanmış bu katman, sınıflandırma modelini sonucunu inceleyerek koşullu çıktılar üretmektedir.

Örneğin: Hiçbir süzgece takılmadan sınıflandırma modelinin çalıştırıldığı katmana kadar gelebilen dört kısa mesaj

“A”, “B”, “C” ve “D” kısa mesajları olarak adlandırın. A kısa mesajının içeriği hatırlatıcı olsun, B’nin içeriği istenmeyen kısa mesaj özelliği gösterebilir. C kısa mesajı da kişisel kısa mesajların özelliklerini barındırsın. D kısa mesajı ise içerisinde ticari nitelikte öğeler bulundursun.

A, B, C ve D mesajlarını telefon rehberinde kayıtlı, yani beyaz liste içerisinde değerlendirilecek bir kişinin gönderdiğini varsayalım. Bu durumda mesajların kişisel olarak mı etiketlenmesi gerekir, yoksa tahmin edilen etiketi ile mi? Bu karışıklığın önüne geçebilmek için makine öğrenmesi modelinin yaptığı tahmini belirli parametreler ile kontrol edilerek sonuç iyileştirilmeye çalışılmıştır.


Model kısa mesajın etiketini tahmin ettikten sonra üç şey kontrol edilir: “Mesaj göndereni kayıtlı mı?”, “Modelin tahmin ettiği etiket ‘hatırlatıcı’ mı?” ve “Modelin tahmin ettiği etiket ‘otp kodu’ mu?”. Eğer gönderen kayıtlı ise ve tahmin edilen etiket “hatırlatıcı” ise A mesajında olduğu gibi mesajın etiketi “hatırlatıcı” olacaktır. Çünkü hatırlatıcı özelliği kişisel özelliğine baskın gelmiştir. Aynı şekilde, gönderen kayıtlı ve tahmin edilen etiket “otp kodu”

ise sonuç “otp kodu” olacaktır. Ancak “hatırlatıcı” ve “otp kodu” sınıflarının dışında rehberde kayıtlı bir kişinin ticari veya istenmeyen mesaj atmış olması düşünülemez. Bu sebeple B ve D mesajlarının sınıflandırma sonuçlarında olduğu gibi sınıflandırma sonucu “kişisel” olacaktır. C mesajı ise zaten “kişisel” özellikleri barındırdığı için model tahmini de kişisel olacak, rehberde kayıtlı olması ile “kişisel” mesaj olduğu teyit edilecektir.


Uygulanan bu yöntemde model çıktı doğruluğunun beyaz liste içeriği ile artırılması amaçlanmıştır.

III. UYGULAMA

Üretilen çok katmanlı süzgeçleme mimarisi *Android Studio* üzerinde JAVA dili kullanılarak gerçekleştirilmiş ve bir mobil uygulama geliştirilmiştir. Geliştirilen uygulama mesaj gönderme, alma, okuma ve silme gibi standart özellikleri bulundurmakla birlikte cihazdaki kısa mesajları sınıflandırılmış bir biçimde kullanıcıya sunmaktadır.



Şekil 4. Uygulama Arayüzü (Mesajların bazı bölümleri bilgi gizliliği gereği maskelenmiştir.)



Şekil 5. Geçmiş Mesajların Toplu Bir Şekilde Sınıflandırılması

Şekil 4’de gösterildiği gibi uygulama arayüzünde “Tüm mesajlar”, “Kişisel”, “Hatırlatıcı”, “OTP Kodları”, “İstenmeyen” ve “Ticari” başlıklarında kısa mesajlarını listeleme ekranları bulunmaktadır. “Tüm Mesajlar” tüm kısa mesajların birlikte listelendiği bir arayüzdür. “Kişisel” ve diğer ekranlarda ise ilgili kategorideki kısa mesajlar listelenmektedir. Bu ekranlar arasında kaydırarak geçiş yapılabilmesi sağlanmıştır.

Uygulama, bulundurduğu yayın alıcısı (*broadcast receiver*) ile telefona gelecek mesajları dinlemektedir. Aynı zamanda “İçe aktar” seçeneği ile telefon hafızasında kayıtlı tüm kısa mesajlar okunarak Şekil 5’te örneklendiği üzere sınıflandırılabilir. Alıcı tarafından yakalanan veya telefon hafızasından okunan kısa mesajlar çok katmanlı süzgeçleme mimarisine tabii tutularak sınıflandırıldıktan sonra etiketleri ile birlikte uygulama veri tabanına kaydedilmektedir. Yeni mesaj geldiğinde bildirim oluşturularak kullanıcı bilgilendirilmektedir.

Mesajlara uzun süre basıldığında Şekil 6’daki gibi mesaj seçenekleri ekranı çıkmaktadır. Her mesaj tipinde “Sil”, “Başka sınıfa gönder” ve “Takvime Ekle” seçenekleri bulunmaktadır. Kullanıcı “başka sınıfa gönder” seçeneği ile

mesajı istediği kategoriye gönderebilmekte, “Takvime Ekle” seçeneği ile mesaj için etkinlik planlayabilmektedir. Ayrıca “Hatırlatıcı” ve “OTP Kodları” mesaj tipleri için özelleştirilmiş bazı ek seçenekler bulunmaktadır.

Hatırlatıcı olarak etiketlenmiş kısa mesajların mesaj seçeneklerinde “Takvime Ekle” seçildiğinde geliştirilen Regex yardımı ile mesaj içerisindeki tarih tespit edilmekte ve etkinlik oluşturma arayüzü ilgili tarihe planlanmış olarak açılmaktadır.


“OTP Kodları” olarak etiketlenmiş mesajlarda ise “Kodu Kopyala” seçeneği bulunmaktadır. Bu seçenek sayesinde mesaj gövdesinde bulunan OTP kodları tespit edilip, cihazın geçici taşıma panosuna (clipboard) kopyalanmaktadır.

Kısa mesajlar kullanım alanları gereği sınırlı boyuttaki metin kümelerinden oluşmaktadır. Bir cihaza bir kısa mesaj ulaştığında beraberinde şu bilgileri de bulundurmaktadır:

Zaman Damgası: Mesajın gönderilme zamanına ait bilgi

Gönderen Numarası: Mesajı gönderen tarafın telefon numarası veya ismi

Mesaj Gövdesi: Göndericinin ilettiği mesajın içeriği



Şekil 6. Mesaj Seçenekleri

IV. PERFORMANS ANALİZİ

Kısa mesajların içerdiği temel bilgilerden yola çıkılarak ne zaman gönderildiği, kimin gönderdiğinin değerlendirilmesi gibi koşulsal sınıflandırma yapılması mümkündür. Ancak metin içerisinden çıkartılabilen anlamsal ve biçimsel özelliklerin elde edilmesi metnin daha doğru bir şekilde daha çok sınıf altında sınıflandırılmasında yardımcı olacaktır.

Metnin sınıflandırılabilmesi için özellik çıkarımına ihtiyaç duyulmaktadır. Bu sebeple bu çalışma altında sınıflandırmaya yönelik özellikler seçilmiş ve özelliklerin sonuçlara etkisi incelenmiştir. “*Temel Biçimsel Özellikler*” başlığı altında kısa mesaj üzerinden elde edilen biçimsel özelliklerden bahsedilmiş; “*adresType ve PartOfDay Özelliğinin Eklenmesi*”, “*letterCaseNormalization Özelliğinin Eklenmesi*” başlıkları altında mesajlardan dolayı yollarla elde edilmiş yeni biçimsel özelliklerin eklenmesinden bahsedilmiştir. “*String2WordVector Filtresinin Kullanılması*” başlığında ise kelimelerin uzaysal alana yerleştirilmesi ile elde edilen özelliklerden ve bu özelliklerin nasıl elde edildiğinden bahsedilmiştir.

Her bölümde karmaşıklık matrislerine yer verilmiş bunun yerine özelliklerin neden seçildiği ve beklenen

etkisinden bahsedilmiştir. Son bölüm olan “*Eklenen Özellikler ile Başarı Değişimlerinin Kıyaslanması*” bölümünde ise sistemin genel başarısını özetleyen testler ve sonuçlar irdelenerek karmaşıklık matrisine yer verilmiştir.

4.1 Temel Biçimsel Özellikler

Sınıflandırma çalışmalarının başlangıcında temel özellikler tespit edilmiş ve sınıflandırma modelleri ile test edilmiştir. Bu adımda kullanılan özellikler, Tablo 4’te gösterilmiştir.

Tablo 4. Temel Biçimsel Özellikler Tablosu

Özellik	Tipi	Açıklama
PercentNumeral	Nümerik	Yüzdelik ifade sayısı / Mesajdaki toplam kelime sayısı
RomanNumeral	Nümerik	Mesajda geçen roma rakamı sayısı / Mesajdaki toplam kelime sayısı
URL	Nümerik	Mesajda geçen URL sayısı / Mesajdaki toplam kelime sayısı
Word	Nümerik	Mesaj içeriğindeki Zemberek sözlüğünde bulunan kelime miktarı / Mesajdaki toplam kelime sayısı
AbbreviationWithDots	Nümerik	Mesajda geçen noktalı kısaltma sayısı / Mesajdaki toplam kelime sayısı
DateX	Nümerik	Tarih ifadesi sayısı / Mesajdaki toplam kelime sayısı
Email	Nümerik	Mesajda geçen e-posta adresi sayısı / Mesajdaki toplam kelime sayısı
Emoticon	Nümerik	Mesajda geçen emoji sayısı / Mesajdaki toplam kelime sayısı
Number	Nümerik	Mesajda geçen numara sayısı / Mesajdaki toplam kelime sayısı
Punctuation	Nümerik	Mesaj içeriğindeki noktalama işareti sayısı / Toplam token sayısı
SpaceTab	Nümerik	BoşlukTab sayısı / Mesajdaki toplam kelime sayısı
total	Nümerik	Toplam kelime sayısı
UnknownWord	Nümerik	Mesaj içeriğindeki Zemberek sözlüğünde bulunmayan kelime miktarı / Mesajdaki toplam kelime sayısı
WordWithApostrophe	Nümerik	Kesme işareti içeren kelime sayısı / Mesajdaki toplam kelime sayısı
TimeX	Nümerik	Zaman ifadesi sayısı / Mesajdaki toplam kelime sayısı
Abbreviation	Nümerik	Kısaltmaların sayısı / Mesajdaki toplam kelime sayısı

Bu özellikler kullanılarak yapılan testlerin sonucu incelendiğinde %78,57 ile en iyi başarıyı Random Forest Algoritması yakalamıştır.

4.2 adresType ve PartOfDay Özelliğinin Eklenmesi

SMS verilerinin tekrar incelenmesi sonucu SMS gönderim zamanının mesajların doğru sınıfa yerleştirilebilmesi için

etkili bir özellik olabileceği fark edilmiştir ve mesajları öğleden önce (am) ve öğleden sonra (pm) bilgisini tutan PartOfDay adında yeni bir özellik eklenmiştir.

SMS'i gönderen adresler bir telefon numarası ya da bir şirket ismi olabilir. Örneğin kişisel bir mesajda gönderen bilgisini tutan Adress değişkenindeki değer "+09 555 123 45 67" şeklinde bir telefon numarası iken; Bir devlet kurumunun Adress değişkeni değeri "PTT TAŞIMACILIK" şeklinde bir String olmaktadır. Ticari mesajların çoğunluğunda Adress değişkeni String içerdiği fark edilmiştir ve bunun bir özellik olarak kullanılmasına karar verilmiştir. SMS mesajı gönderen bilgisinden elde edilen adressType özelliği String ve number olarak mesajların gönderenlerini iki tipe ayırmaktadır.

4.3 String2WordVector Filtresinin Kullanılması

Bu başlığa kadar kullanılan özellikler SMS gövdesinden elde edilmiş oransal verilerden oluşmaktadır. Örneğin Tablo 5'deki kısa mesajda URL 1 kere kullanılmıştır, bu sayı tüm simgelere oranlandığında elde edilen değer 0,09 ($1/(simge\ sayısı=11)$) olacaktır. URL özelliğinde olduğu gibi diğer oransal değerler de bu yolla elde edilmiştir.

Tablo 5. Önişleme adımı olarak simgeleme yöntemi örneği

SMS Gövdesi:	
"Kampanya : 30.01.2018 tarihine kadar B3SEW4 kodu ile indirimli alışveriş şansı : http://www.abcd.com "	
Sonuç:	
Simge	Tip
Kampanya	Word
30.01.2018	Date
tarihine	Word
kadar	Word
B3SEW4	WordWithApostrophe
kodu	Word
ile	Word
indirimli	Word
alışveriş	Word
şansı	Word
http://www.abcd.com	URL

Özellikler Zemberek kütüphanesi yardımı ile *tokenize* edilmekte ve *tipleri* toplam kelime sayısına oranlanarak (normalizasyon) yeni özellikleri Tablo 3'de ifade edildiği gibi çıkarılmaktadır. Literatürdeki metin sınıflandırma çalışmaları incelendiğinde, metinlerin sınıflandırılmasında *StringtoWordVector* gibi filtreler ile ön işlemlerden geçirilerek yeni özellikler çıkarılmaktadır.

Bu bölümde SMS gövdelerinden elde edilen yeni özellikler kullanılarak sınıflandırma sonuçlarının iyileştirilmesi

amaçlanmaktadır. Zemberek kütüphanesi yardımı ile SMS gövdesi sırasıyla; tokenize edilir, kelime tipinde ise tokenize edilecek ve kullanılmak üzere kaydedilecek eğer kelime tipinde değilse özellik tipi kaydedilir. Örnek olarak verilen Tablo 3 yeni yaklaşımın girdi ve çıktıları göstermektedir.


SMS gövdelerinin Tablo 3'de örneklendirilen şekilde ön işleminden geçirilmesi sonucu WEKA içerisindeki arff formatlı dosyaya *@attribute roots string* satırı eklenmiştir. *roots* özelliği *StringtoWordVector* Filtresinden geçirilerek yeni özellik çıkarımları için kullanılır.

4.4 letterCaseNormalization Özelliğinin Eklenmesi

Cümle içerisindeki küçük büyük harf oranı normalizasyonu yapılarak letterCaseNormalization özelliği oluşturulmuştur.


4.5 Eklenen Özellikler ile Başarı Değişimlerinin İncelenmesi

Her bir adımda eklenen yeni özellikler ve uygulanan yöntemler sınıflandırma modeli başarısına katkıda bulunmuştur. Verisetinin sınıf dağılımının dengesiz olması nedeni ile başarı değerlendirmesi yapılırken mikro ve makro doğruluk değerleri hesaplanmıştır. Şekil 7'de ve Şekil 8'de test edilen her bir algoritmanın yeni eklenen özelliklere bağlı olarak değişen makro ve mikro doğruluk oranlarına yer verilmiştir.



Şekil 7. Model Çıktılarının Mikro Doğruluk Bazında Eklenen Özelliklere Göre Karşılaştırılması

Random Forest algoritması ile oluşturulan model her adımda en başarılı sonuçları vermiştir. Mikro doğruluk bazında incelendiğinde, başlangıçta Random Forest ile doğru sınıflandırılan örnek oranı %78,57 iken yapılan çalışmalar sonucu bu oran %87,17'ye çıkarılmıştır. Benzer şekilde makro doğruluk bazında elde edilen çıktılar incelendiğinde Random Forest'ın tüm özellik testlerinde en yüksek sonuçları verdiği görülmüştür.



Şekil 8. Model Çıktılarının Makro Doğruluk Bazında Eklenen Özelliklere Göre Karşılaştırılması

V. UYGULAMA METRİKLERİ

Sistem mimarisi sunduğu çok katmanlı mimari sayesinde mesajları daha hızlı bir şekilde kategorize etmeyi hedefler. Bu amaca yönelik yapılan çalışmaların sonucunda mesajların sınıflandırılmasında doğruluk ve hız artışı gözlemlenmiştir. Tablo 6’da “yalnızca sınıflandırma modeli kullanılması” ve “çok katmanlı süzgeçleme mimarisi kullanımı” durumlarında elde edilen zaman ve doğruluk oranı metriklerine yer verilmiştir.

Tablo 6. Karşılaştırmalı Uygulama Metrikleri

	Yalnızca Sınıflandırma Modeli Kullanıldığında	Çok Katmanlı Süzgeçleme Mimarisi Kullanıldığında
Ortalama Mesaj Sınıflandırma Süresi (ms)	23ms	19ms
Doğru Sınıflandırma Oranı (%)	%87,17	%93,48

Tablo 6’da elde edilen sonuçlar göz önünde bulundurulduğunda “Çok Katmanlı Süzgeçleme Mimarisi” kullanıldığında bir mesajın ortalama sınıflandırma süresi azalmış ve doğru sınıflandırılma oranı artmıştır.

Tablo 7’de sistemin genel başarımını ölçümleyen bir karmaşıklık matrisi gösterilmiştir. Karmaşıklık matrisi üzerindeki verilerin anlaşılabilirliğini arttırmak için kesinlik ve hassasiyet değerleri hesaplanmıştır. Kesinlik (precision) pozitif olarak tahmin edilen bir durumdaki başarıyı gösteren değerdir. Hassasiyet (recall) ise pozitif durumların ne kadar başarılı tahmin edildiğini gösteren değerdir.

Tablo 7 incelendiğinde karmaşıklık matrisinde bazı sınıfların birbiri ile karıştırıldığı dikkat çekmektedir. Özellikle *hatırlatıcı-ticari* ve *istenmeyen-ticari* sınıfları arasında yüksek miktarda karışma olduğu gözlemlenmektedir. Bu karışıklığın sebebi ticari mesajların ve hatırlatıcı mesajlarının

içeriklerinin anlamsal ve biçimsel yönlerden benzer olabilmesi ile açıklanabilir. Örneğin ticari içeriğe sahip bir mesaj gövdesi “*Ayakkabılarda sezon indirimi! Son gün 28 Eylül!*” olsun. Bu mesaj anlamsal olarak değerlendirildiğinde hem “*hatırlatıcı*” hem “*ticari*” mesaj niteliği taşımaktadır. Veri seti üzerinde örnekteki benzer mesajlar incelendiğinde bu karışıklığın sebebinin etiketleme işlemindeki etiketleyicinin tercihidir. Aynı şekilde “*istenmeyen*” ve “*ticari*” sınıflarında bir mesajın hangi sınıfa ait olduğu göreceli bir kavramdır. Antalya’da bir otelin reklamını içeren kısa mesaj yakın zamanda tatil planlayan birisi için “*ticari*” kısa mesaj niteliği taşıırken, tatil planlamayan başka bir kimse için “*istenmeyen*” niteliği taşıyabilir. Bu karmaşıklıkların engellenmesi için sunulan öneri “Sonuç ve Gelecek Çalışmalar” başlığında açıklanmıştır.

Öte yandan, Zemberek’in kullanımının başarıya etkisi incelendiğinde yapılan testler sonucu sınıflandırma başarısının %2 arttığı gözlenmiştir. Teorik olarak köklere ayrılan kelimelerin StringToWordVector filtresine etkisi köklere ayrılmamış örneklerle göre daha fazladır. Zemberek’ten elde edilen kelime kökleri ve özellikler kullanılmadığında oluşan doğruluk farkının az olmasının sebebi kullanılan veri setinin kelime bazında zengin olmamasından kaynaklanmaktadır. Daha geniş bir coğrafyadan, farklı yaş aralıkları ve düşüncelerden insanların kısa mesajları ile oluşturulmuş bir veri seti ile yapılacak testlerde sonuçlardaki farkın daha belirgin olması beklenmektedir.

Tablo 7. Karmaşıklık Matrisi

Gerçek Sınıf							
Tahmin Edilen Sınıf	kişisel	ticari	hatırlatıcı	otp kodları	istenmeyen	Toplam	Precision
kişisel	824	1	5	1	8	839	%98,21
ticari	0	226	15	3	1	245	%92,25
hatırlatıcı	7	36	464	2	1	510	%90,98
otp kodları	3	14	7	107	1	132	%81,06
istenmeyen	1	5	3	2	43	54	%79,63
Recall	%98,68	%80,14	%93,93	%93,04	%79,63		

VI. SONUÇ VE GELECEK ÇALIŞMALAR

Bu çalışmada Türkçe mesajlar için metin sınıflandırma yaklaşımlarından faydalanılarak mesajları beş farklı kategoriye ayıran mesaj asistanı uygulaması gerçekleştirilmiştir. Mesajları sınıflar halinde kategorize edebilmek için mesajların yapıları incelenip doğru sonuca götürecek özellikler belirlenmiştir. Adım adım özellikler belirlenirken her yeni eklenen özelliğin sınıflandırma sonucuna etkisi incelenmiştir. Sınıflandırma sonuçlarının yeni özelliklere göre değişimini incelerken Naive Bayes, Bayes Net, J48 ve Random Forest algoritmaları kullanılmıştır. Yapılan çalışmalar sonucunda Random Forest yöntemi %87,17 ile doğruluk oranı ile en

iyi sınıflandırma algoritması olmuş ve uygulamada bu algoritma kullanılmıştır. Ayrıca içerisinde 4 adet filtre bulunan çok katmanlı süzgeçleme mimarisi sayesinde 5 farklı mesaj kategorisi %93 oranında bir başarı ile daha kısa sürede gruplanabilmiştir. Ucuz ve etkili bir iletişim yöntemi olan SMS, pazarlama, kişisel, doğrulama vb. birçok amaçla kullanılan bir yöntemdir. Mesajların çeşitliliğinin artması ile mesajların okunabilirliği ve erişilebilirliği azalmaktadır. Geliştirilen uygulama ile kullanıcıların SMS gelen kutularını daha organize ve verimli kullanmasını sağlayarak, farklı mesajların yoğun bir şekilde bir arada bulunması yüzünden vakit ve enerji kaybının engellenmesi sağlanmıştır.

Öte yandan belirlenmiş sayıda sınıfı bulunan organize edilmiş bir kısa mesaj gelen kutusu kullanıcıların gereksinimlerini karşılayabilir olmasına rağmen, gelecek çalışmalarda daha özelleşmiş bir gelen kutusu deneyimi için kullanıcıların kendilerine ait sınıfları oluşturabilmesi ve sistemin eğitilebilir olması bu sayede kullanıcı memnuniyetinin ve kullanım kolaylığının artırılması hedeflenmektedir. Kullanıcının sınıf sayısını özelleştirmesi gibi kendi mesajları ile sistemi eğitilmesi kişiselleştirilmiş bir sınıflandırma sistemini oluşturulmasına yönelik çalışmalar planlanmaktadır. Bu sayede veri setinin etiketlenmesi sırasında etiketleyicinin göreceli yaklaşımı nedeniyle oluşabilecek hatalar kullanıcının sistemi kendi mesajları ile eğitmesi sonucu en aza indirgenebilecektir.

VII. BİLGİ

Bu proje TÜBİTAK tarafından organize edilen “2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı” kapsamında desteklenmektedir.

Kaynaklar

- [1] Zhu, S., Ji, X., Xu, W., & Gong, Y. (2005, August). Multi-labelled classification using maximum entropy method. In *Proceedings of the 28th annual international ACM SIGIR conference on Research and development in information retrieval* (pp. 274-281). ACM.
- [2] Klimt, B., & Yang, Y. (2004, September). The enron corpus: A new dataset for email classification research. In *European Conference on Machine Learning* (pp. 217-226). Springer, Berlin, Heidelberg.
- [3] Healy, M., Delany, S. J., & Zamolotskikh, A. (2004). An assessment of case base reasoning for short text message classification In *Proceedings of the 15th. Irish Conference on Artificial Intelligence and Cognitive Sciences (AICS'04)*, pp.9-18, 2004.
- [4] Najadat H., Abdulla, N., Abooraig, R. ve Nawasrah S. (2014). Mobile SMS Spam Filtering based on Mixing Classifiers. *International Journal of Advanced Computing Research*, 1.
- [5] Joe, I., & Shim, H. (2010, December). An SMS spam filtering system using support vector machine. In *International Conference on Future Generation Information Technology* (pp. 577-584). Springer, Berlin, Heidelberg.
- [6] Mahmoud, T. M., & Mahfouz, A. M. (2012). SMS spam filtering technique based on artificial immune system. *International Journal of Computer Science Issues (IJCSI)*, 9(2), 589.
- [7] Patel, F. N., & Soni, N. R. (2012). Text mining: A Brief survey. *International Journal of Advanced Computer Research*, 2(4), 243-248.
- [8] Al-Talib, G. A., & Hassan, H. S. (2013). A study on analysis of SMS classification using TF-IDF Weighting. *International Journal of Computer Networks and Communications Security*, 1(5), 189-194.
- [9] Parimala, R., & Nallaswamy, R. (2012). A Study on Analysis of SMS Classification Using Document Frequency Thresold. *International Journal of Information Engineering and Electronic Business*, 4(1), 44.
- [10] Deng, W. W., & Peng, H. (2006, August). Research on a naive bayesian based short message filtering system. In *Machine learning and cybernetics, 2006 international conference on* (pp. 1233-1237). IEEE.
- [11] Kawade, D. R., & Oza, K. S. (2015). SMS spam classification using WEKA. *International Journal of Electronics Communication and Computer Technology*, 5, 43-7.
- [12] Mathew, K., & Issac, B. (2011, December). Intelligent spam classification for mobile text message. In *Computer Science and Network Technology (ICCSNT), 2011 International Conference on* (Vol. 1, pp. 101-105). IEEE.
- [13] Uysal, A. K., Günel, S., Ergin, S., & Günel, E. Ş. (2012, April). Detection of SMS spam messages on mobile phones. In *Signal Processing and Communications Applications Conference (SIU), 2012 20th* (pp. 1-4). IEEE.
- [14] Kilic, E., Arslan, S. N., & Guvensan, M. A. (2014, April). 3-Tier hybrid approach for SMS filtering. In *Signal Processing and Communications Applications Conference (SIU), 2014 22nd* (pp. 1950-1953). IEEE.
- [15] StringToWordVector. (2016, April 14). Retrieved July/August, 2018, from <http://weka.sourceforge.net/doc.stable/weka/filters/unsupervised/attribute/StringToWordVector.html>
- [16] Naive Bayes Slide. (2017). Retrieved July 23, 2018, from <https://web.stanford.edu/class/cs124/lec/naivebayes.pdf>
- [17] Cooper, G. F., & Herskovits, E. (1992). A Bayesian method for the induction of probabilistic networks from data. *Machine learning*, 9(4), 309-347.
- [18] J48. (2018, September 04). Retrieved July 23, 2018, from <http://weka.sourceforge.net/doc.dev/weka/classifiers/trees/J48.html>
- [19] Kaur, G., & Chhabra, A. (2014). Improved J48 classification algorithm for the prediction of diabetes. *International Journal of Computer Applications*, 98(22).
- [20] Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R news*, 2(3), 18-22.