

T.C.
AKDENİZ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

TRİYAJ VERİSİ KULLANARAK ÖNTANI TAHMİNİ
YAPAN YAPAY ZEKA TABANLI KARAR DESTEK
SİSTEMİ

GÖKSU BOZDERELİ BERİKOL

DOKTORA TEZİ

2023-ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

TRİYAJ VERİSİ KULLANARAK ÖNTANI TAHMİNİ
YAPAN YAPAY ZEKA TABANLI KARAR DESTEK
SİSTEMİ

GÖKSU BOZDERELİ BERİKOL

DOKTORA TEZİ

DANIŞMAN

Doç. Dr. Uğur BİLGE

“Kaynakça gösterilerek tezimden yararlanılabilir”

2023-ANTALYA

Sağlık Bilimleri Enstitüsü Müdürlüğüne;

Bu çalışma jürimiz tarafından Biyoistatistik ve Tıp Bilişimi Anabilim Dalı Tıp Bilişimi Programında doktora tezi olarak kabul edilmiştir. .../...../.....

İmza

Tez Danışmanı : Doç. Dr. Uğur BİLGE

Akdeniz Üniversitesi

Üye : Prof. Dr. Murat CANPOLAT

Akdeniz Üniversitesi

Üye : Prof. Dr. Serdar KULA

Gazi Üniversitesi

Üye : Doç. Dr. Neşe ZAYİM

Akdeniz Üniversitesi

Üye : Doç. Dr. Oktay YILDIZ

Gazi Üniversitesi

Bu tez, Enstitü Yönetim Kurulunca belirlenen yukarıdaki jüri üyeleri tarafından uygun görülmüş ve Enstitü Yönetim Kurulu'nun/...../..... tarih ve/..... sayılı kararıyla kabul edilmiştir.

Enstitü Müdürü

ETİK BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı beyan ederim.

Göksu BOZDERELİ BERİKOL

İmza

Tez Danışmanı

Uğur BİLGE

İmza

TEŐEKKÖR

Tıp Biliőimi doktora eęitimim sűrecinde desteklerini esirgemeyen ve bu alıőmanın ortaya ıkmasında bana yol gűsterici olan deęerli danıőmanım Do. Dr. Uęur BİLGE'ye, tez sűrecinde deęerli katkılarını esirgemeyen hocam Prof. Dr. Murat CANPOLAT ve Prof. Dr. Ahmet YARDIMCI'ya doktora sűrecim boyunca bilgilerini, yardımlarını ve desteklerini esirgemeyen deęerli hocalarım, Do. Dr. Neőe ZAYİM, Do. Dr. Kemal Hakan GÖLKESEN'e, acil tıp uzmanlıęımdan beri mentörlüęü ile her daim yol gűsteren deęerli hocam Prof. Dr. Cem OKTAY'a, bölümdeki varlıkları ve desteklerinin benim için ok büyük deęeri olan Araő. Gör. Hazal TAő, Araő. Gör. Nevruz İLHANLI'ya, yüzyüze ve online her aőamada yardımlarını, katkılarını esirgemeyen arkadaşım Hasibe YILDIZ baőta olmak üzere doktora eęitim sűrecini beraber geirdięimiz Akdeniz Üniversitesi Tıp Fakóltesi Biyoistatistik ve Tıp Biliőimi Anabilim Dalı'nda tüm dönem arkadaşlarıma, hayatımın her döneminde akademik yaőamıma yön veren ve sabırla yanımda olup beni yalnız bırakmayan deęerli ailem annem Hilal BOZDERELİ'ye, babam Durhasan BOZDERELİ'ye, kardeőim Dicle BOZDERELİ'ye, eőim Gürkan BERİKOL'a ve kızım Nilsu BERİKOL'a sonsuz teőekkür ederim.

ÖZET

Amaç: Acil servislerde öntanı ve triyaj kararı hastaların şikayet ve klinik durumlarına göre yapılmaktadır. Bu çalışmada şikayet metinleri kullanılarak triyaj, öntanı ve yatış kararlarının, makine öğrenmesi tabanlı bir karar destek sistemi ile tahmini amaçlanmıştır.

Yöntem: Ocak 2018-Temmuz 2019 tarihleri arasında eğitim ve araştırma hastanesi acil servise başvuran hastalar çalışmaya alındı. Çalışmada şikayet metinlerinin doğal dil işlem sonrası XGBoost, rastgele orman(RF) ve yapay sinir ağları(YSA) kullanılarak triyaj ve öntanı tahminleri yapıldı.

Bulgular: Çalışmaya alınan 54.867 hasta verisi içerisinde en fazla sarı triyajı(%76,4) saptandı. En çok kaydedilen üç tanı; akut batın (%14), üst solunum yolu enfeksiyonu(%10,3) ve diyare(%6,1); ikili n-gramlar içerisinde en sık kullanılan kelime çifti karın ağrısı, göğüs ağrısı ve baş ağrısı olduğu saptandı. Sonlanım tahmininde en başarılı yöntem 0,931 doğrulukla yapay sinir ağlarında, triyaj tahmininde ise duyarlılıklar en çok sarı ve ESI 3 olmak üzere XGB (0,771; %95 CI 0,763-0,777), rastgele orman (0,765; %95CI 0,760-0,773) ve YSA'nda(0,766; %95CI 0,760-0,772) olduğu saptanmıştır. Öntanılar arasında nörolojik acillerin tahminine yönelik en yüksek seçicilik XGB(0,936) ve RF(0,936) ile, kardiyovasküler aciller grubunda ise seçicilik yine XGB (0,865) ve RF'de(0,865) daha yüksek bulundu.

Sonuç: Yapılandırılmamış şikayetler ile triyaj ve öntanı tahmin etmede üç yöntemin de duyarlılıkları sarı ve ESI 3 hastaları için yüksek olurken, sonlanım tahmininde en yüksek doğruluk yapay sinir ağlarında saptanmıştır. Bu modeller acil servise başvuran hastaların hayati öntanı kararı ve taburculuğunda klinisyene yardımcı olabilir.

Anahtar Kelimeler: Doğal dil işleme, Makine öğrenmesi, Triage, Yapay Sinir Ağları

ABSTRACT

Objective: The aim of this study was to predict triage, preliminary diagnosis and admissions using a machine learning-based decision support system from complaint texts.

Methods: Patients admitted to the emergency department of training and research hospital between Jan 2018 and Jul 2019 were included in the study. Triage and preliminary diagnosis predictions were made using XGBoost, Random Forest(RF), and Artificial Neural Networks(ANN) after Natural Language Processing of chief complaints text.

Results: Out of the 54,867 patient data included in the study, yellow triage was found to be the most prevalent(76.4%). The three most frequently recorded diagnoses were acute abdomen(14%), upper respiratory tract infection(10.3%), and diarrhea(6.1%); within bi-grams, the most frequently used word pairs were abdominal pain, chest pain, and headache. For prediction of outcomes, the most successful method was ANN with an accuracy of 0.931. For triage prediction, the highest sensitivities were found in yellow and ESI 3 triages, specifically in XGB(0.771; 95% CI 0.763-0.777), random forest(0.765; 95% CI 0.760-0.773), and ANN(0.766; 95% CI 0.760-0.772). The highest specificity towards predicting pre-diagnoses, neurological ones was with XGB (0.936) and RF (0.936), and in the cardiovascular, specificity was again higher in XGB(0.865) and RF(0.865).

Conclusion: While the sensitivities of the three methods in predicting triage and pre-diagnosis with unstructured complaints were found to be high for patients in yellow and ESI 3 categories, the highest accuracy in outcome prediction was detected in artificial neural networks. These models can aid clinicians in mortal pre-diagnosis and discharge decisions in emergency department.

Keywords: Natural Language Processing, Machine Learning, Triage, Artificial Neural Networks.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TABLolar DİZİNİ	iv
ŞEKİLLER DİZİNİ.....	vi
SİMGELER VE KISALTMALAR.....	vii
1. GİRİŞ	1
2. GENEL BİLGİLER	3
2.1.TRİYAJ	3
2.2.YAPAY ZEKA	11
2.3.DOĞAL DİL İŞLEME(NLP)	14
3. GEREÇ VE YÖNTEM	23
3.1 VERİLERİN TOPLANMASI.....	23
3.2.ESI DÜZEYLERİNİN BELİRLENMESİ VE ŞİKAYET VERİLERİNİN İŞLENMESİ.....	26
3.3.İSTATİSTİKSEL VE MAKİNE ÖĞRENMESİ İLE TAHMİNSEL ANALİZ	33
3.4.R SHİNY İLE KARAR DESTEK SİSTEMİNİN OLUŞTURULMASI.....	37
4. BULGULAR	38
4.1.YAPILANDIRILMIŞ VERİLERİN ANALİZİ	38
4. TARTIŞMA	48
5. SONUÇ VE ÖNERİLER	59
6. KAYNAKLAR	60
7. ÖZGEÇMİŞ	73
8. EKLER.....	85

TABLÖLAR DİZİNİ

Tablo 1.1	Kapsamları ve renklerine göre triyaj seviyeleri	3
Tablo 2.1	Veri madenciliği basamakları	12
Tablo 2.2	Veri madenciliği modelleri	13
Tablo 2.3	Metin madenciliğine ait veri işleme teknikleri	17
Tablo 3.1	Verilerin analizine yönelik yapılacak işlemler	20
Tablo 3.2.	ESI düzeylerinin açıklamaları	21
Tablo 3.3.	Hastaların kaynak, malzeme, ilaç kullanımlarına göre ESI düzeylerinin belirlenmesine ait kurallar	23
Tablo 3.4.	Orjinal ve kısaltılmış örnek şikayet metni	25
Tablo 3.5.	Örnek cümlelerle metin ön işleme	27
Tablo 4.1.	Yapılandırılmış değişkenlerin sayı ve dağılımları	34
Tablo 4.2.	3'lü ve 5'li triyaj (ESI) kategorilerine göre hasta dağılımları	35
Tablo 4.3.	Üçlü triyaj tahminlerine ait çapraz tablolar	38
Tablo 4.4	Üçlü triyaj tahminlerinin sensitivite, spesifisite, PPV, NPV, doğruluk ve kappa değerleri	38
Tablo 4.5	ESI triyaj tahminlerine (ESI) ait çapraz tablolar	39

Tablo 4.6	Beşli triyaj tahminlerinin (ESI) sensitivite, spesifisite, PPV, NPV, doğruluk ve kappa değerleri	40
Tablo 4.7	Öntanı tahminlerine ait çapraz tablolar	41
Tablo 4.8	Öntanı tahminlerinin sensitivite, spesifisite, PPV, NPV, doğruluk ve kappa değerleri	42



ŞEKİLLER DİZİNİ

Şekil 1.1	ESI triyaj işleyiş algoritması	7
Şekil 2.1	Hasta başvurusu sonrası hasta bakım ve tanı oluşturma süreci	10
Şekil 2.2	Veri madenciliği iş akışı	13
Şekil 3.1	ESI triyaj düzeylerini belirlemede kullanılan algoritma akış diyagramı	24
Şekil 3.2	R Shiny karar destek sistemi	31
Şekil 4.1	Çalışmaya dahil etme kriterleri	32
Şekil 4.2.	ESI ve triyaj renklerine göre dağılım grafiği	35
Şekil 4.3	Şikayet metinlerinde en sık kullanılan bigramlara ait kelime bulutu	36
Şekil 4.4	En sık kullanılan kelimelere ait n-gram grafiği	37
Şekil 5.1	Literatürde kullanılan çalışmalardaki değişkenlerin dağılımı	48

SİMGELER ve KISALTMALAR

HBS	:Hastane Bilgi Sistemi
ATS	: Avustralasya Triyaj Skalası
CTAS	: Kanada Triyaj ve Aciliyet Skalası
CEDIS	: Kanada Acil Servis Bilgi Sistemi
ESI	: Aciliyet Şiddet İndeksi
CDC	: Hastalık Kontrol ve Önleme Merkezi
DEEDS	: Acil Servis Sistemleri için Veriseti Elemanları
NLP	: Doğal Dil İşleme
XGBOOST	: Ekstrem Gradyan Arttırma
RF	: Rastgele Orman
YSA	: Yapay Sinir Ağları
DNN	: Derin Sinir Ağları

1. GİRİŞ

Acil servise başvuran hastalarda ilk başvuru alanı triyaj alanıdır. Triage hastaların aciliyetlerine göre sınıflandırılması olarak tanımlanmıştır. Acil servis triyaj alanlarında hastadan alınan şikayet ve vital bulgu (kalp hızı, kan basıncı, oksijen saturasyonu, solunum sayısı, vücut sıcaklığı) verileri ile hastanın aciliyet derecesine ve hekime ulaşma süresine karar verilmektedir. Bu veriler aynı zamanda hastanın öntanılarını oluşturmada anahtar rol üstlenmektedir. Bu veriler baz alınarak genişletilen soru ve muayenelerle de hastaya kullanılacak kaynaklara (laboratuvar ve görüntüleme tetkikleri, tedavi ve girişimsel işlemler gibi) karar verilmektedir.

Bu veriler hastaneler arası değişebilmekle birlikte hastane bilgi sisteminde(HBS) ya da kağıt üzerindeki hasta bilgi formlarında ayrılmış ilgili bölümlere yapılandırılmış ya da yapılandırılmamış bir formatta kaydedilmektedir.

Acil servislerde triyaj birimlerinde hastaların aciliyetlerinin belirlenmesinde her ne kadar belirli standartlar kullanılsa da bu konuda net bir standart bulunmamaktadır. Acil servislerde hekime ulaşma süresi yada hastanın maksimum bekleme süresi kararı hızlı ve etkin bir şekilde verilmesi gerekmektedir. Bu nedenle bu kararın triyaj personeli deneyimi yada eğitiminden oluşan farklılıklar yada kişilerin gün içinde verdikleri kararın değişiminden etkilenmemesi gerekir. Hastaların kendilerini ifade şekilleri de değişiklik göstermekte, bu da triyaj personelinin eğitim yada deneyim düzeylerine göre şikayetleri farklı şekillerde yapılandırmasına neden olabilmektedir. Yapay zeka modelleri standardize olmasa da dil içerisinde bilinmeyen belirli ağırlıklandırmalar ile sınıflandırabilmekte ve eğitildikçe kendini geliştirebilmektedir. Bu nedenle yapay zeka,

gün içerisindeki deęişimler, kişiler arası eğitim/deneyim farklılıkları ya da yorgunluktan etkilenmeden hızlı, etkin ve standardize olarak sınıflandırma yapabilir.

Karar noktalarında acil servis çalışanlarına yardımcı materyal çok olmasına karşın gerçek verilerle eğitilebilir, yapay zeka ve makine öğrenmesi ile karar verebilir sağlık bakım rutininde kullanılan standart bir sistem bulunmamaktadır. Bu çalışmada hekimin ve triyaj personelinin belirli kurallara dayanarak verdiği kararlara yardımcı olabilecek, yapay zeka tabanlı bir karar destek sistemi geliştirilmesi planlanmaktadır.

Çalışmamızda yapılandırılmamış şikayet verilerinin makine öğrenmesi yöntemleri kullanılarak öntanı ve triyaj düzeyi tahmini yapan karar destek sistemi geliştirilmesi amaçlanmıştır. Çalışmamız gerçek hasta verilerinden öğrenilmiş ve test edilmiş sistemin gelecekte hastane bilgi sistemi ya da mobil uygulamalara entegre edilebilecek acil servis çalışanlarına yardımcı triyaj karar destek sisteminin bir ön çalışması niteliğindedir.

2. GENEL BİLGİLER

2.1. TRIYAJ

2.1.1. TANIM

Triyaj Fransızca ayıklamak, seçmek anlamına gelen “*trier*” sözcüğünden türetilmiş olup hastaların aciliyetlerine göre sınıflandırılması anlamına gelmektedir (K.V. Iserson and Moskop 2007). Amaç aciliyeti olan kişilerin hızlı ve etkin şekilde sağlık bakım sağlayıcıları ve kaynaklara ulaşmasını sağlamaktır. Triyaj türleri arasında acil servis triyajı, yoğun bakım triyajı, afet triyajı, savaş alanı triyajı gibi türleri mevcuttur (K.V. Iserson and Moskop 2007)

2.1.2. TARİHÇE

Fransa’da birinci dünya savaşında askeri doktorların tıbbi yardıma ihtiyaç duyanların savaş alanından ayırarak bakım vermesi triyajın ilk örneği olarak değerlendirilmektedir (K. V. Iserson and Moskop 2007). Aynı yüzyılda Napolyon’un ordusunda görev alan askeri cerrah Dominique Jean Larrey tarafından hastaları yaralanmalarının şiddeti ve acil cerrahi gerekliliğine göre ayırması ile ilk triyaj kavramı ortaya konmuştur. 1900’lu yılların başında Amerika Birleşik Devletleri (ABD), Birleşik Krallık ve Avrupa’da sağlık hizmetlerinin gelişmesi ile acil servislerde ve hastane öncesi alanda triyaj kullanıma başlanmış, kısa bir değerlendirme sonrası nakil zamanı, bekleme süresi ve kaynak kullanım gerekliliğini içeren karar algoritmalarına uygulanmıştır (K. V. Iserson and Moskop 2007). Böylelikle triyaj hastane öncesi sağlık hizmetlerinin sahaya yönlendirilmesinde, hastane öncesi sahadaki bakıda ve hastaneye varışta olmak üzere üç

fazda kullanıma geçmiştir. Başlangıçta travma, savaş alanında kullanılan triyaj genişletilerek kritik hasta ve kronik hastalıklardan küçük yaralanmalara, şikayetlerden fizyolojik parametrelerin de karara yardımcı olmasına kadar kapsamı genişletilmiştir(K. V. Iserson and Moskop 2007)

2.1.3. TRIYAJ UYGULAMALARI

Triyaj uygulamaları hastane öncesi alanda ve hastane acil servislerinde birbirinden bağımsız olarak uygulanmaktadır. Triyaj iki, üç, dört ve beş düzeyli sistemlerden oluşabilmektedir(O'Neill and Molczan 2003; Fernandes et al. 2005) (Tablo 1.1).

Tablo 1.1 Kapsamları ve renklerine göre triyaj seviyeleri

TRİYAJ	1	2	3	4	5
2 düzey	Acil	Acil Değil			
3 düzey	Çok acil	Acil	Acil değil		
4 düzey	Hayatı tehdit edici	Çok acil	Acil	Acil değil	
Manchester	Hemen 0 dk	Çok acil 10 dk	Acil 60 dk	Standart 120 dk	Acil olmayan 240 dk
Kanada	Resusitasyon 0dk	Çok acil 15 dk	Acil 30 dk	Daha az acil 60 dk	Acil olmayan 120 dk
Avustralasya	Hemen 0 dk	Kritik 10 dk	Potansiyel hayatı tehdit edici/ Acil 30 dk	Potansiyel ciddi/yarı acil 60 dk	Daha az acil/ acil olmayan 120 dk
Güney Afrika	Hemen öncelik	Çok acil öncelik	Acil öncelik	Gecikmiş öncelik	Ölü
ESI	Resusitasyon	Yüksek risk	İkiden fazla kaynak gerektiren	Tek kaynak gerektiren	Kaynak gerekirmeyen

Bazı triyaj sistemleri semptom bazlı sistemler olup, hastanın şikayetlerine ve eşlik eden durumlara yönelik sorularla triyaj düzeyi kararını vermektedir (Pardey 2006; Veen et al.

2008; Bullard et al. 2017). Bu triyaj yöntemlerinden bir kısmı şikayet ve vital bulgular gibi fizyolojik parametrelere göre bir kısmı da kaynak kullanımına göre karar vermektedir (Gilboy et al. 2005). Bu kararlarda güvenilirlik ve geçerliliği tanımlanmış triyaj kuralları hastaların aciliyetlerinin belirlenmesinde dünya da sıklıkla kullanılmaktadır (Considine et al. 2004; M.R. Baumann and Strout 2005; Van Veen et al. 2008; Bullard et al. 2008; Twomey et al. 2012).

2.1.4. TRIYAJ SKALALARI

2.1.4.1. AVUSTRALASYA TRIYAJ SKALASI (ATS)

Avustralya ve Yeni Zelanda acil servislerinde hastaların tıbbi değerlendirme ve tedaviye ulaşana kadar maksimum bekleme zamanını belirlemek için kullanılmakta olan 1990'lı yıllarda Ulusal Triage Skalası (National Triage Scale) üzerinden geliştirilmiştir (Considine et al. 2004). Beş kategorili ATS Kategori 1 hemen değerlendirme ve tedavi gerektiren yaşamı tehdit eden bir durumu tanımlarken Kategori 5 ise 120 dakika içinde değerlendirilip tedavi edilebilecek kronik veya minör bir durumu tanımlamaktadır (Pardey 2006).

2.1.4.2. KANADA TRIYAJ VE ACİLİYET SKALASI (CTAS)

Kanada menşei beş seviyeli bir triyaj skalası Avustralasya triyaj skalasını takiben ilk olarak 1995 yılında Kanada Acil Hekimleri Derneği tarafından kendi adında Triage ve Aciliyet Skalası olarak oluşturulmuş, 1999 yılında Kanada Triage ve Aciliyet Skalası adını alarak 2016 yılına kadar revizyonlarla genişletilmiştir (Grafstein, Unger, Bullard, and Innes 2003). Kendine ait başvuru şikayet listesi (CEDIS) olan bu triyaj sistemi pediatrik,

yetişkinler, hastane öncesi gibi durumlar için ayrı kategorize edilmiştir. Ambulansla ya da ayaktan başvuran hastaların CTAS'ta triyaj süreci şu şekilde tanımlanmıştır:

1. Hastanın varışı (Kritik bakı)
2. Enfeksiyon taraması
3. Triyaj değerlendirmesinin uygulanması
4. Başvuru şikayetinin kayıt edilmesi
5. Özellikli modifikatörlerin gözden geçirilmesi
6. Triyaj seviyesinin belirlenmesi
7. Bekleme/tedavi odasına alınması
8. Semptomatik tedavi uygulanması ya da bakım protokollerinin başlatılması
9. Bekleyen hasta ise tekrar triyaj değerlendirmesi

Kanada Triyaj ve Aciliyet Skalasında kritik ilk bakı, hastaların acil servis triyaj odasına girmesi ile başlamaktadır. Hızlı bir A (Havayolu-Airway), B (Solunum-Breathing), C (Dolaşım-Circulation), D (Nörolojik durum-Disability) ilk bakı 3-5 saniyeyi almaktadır. Gerekiyorsa müdahaleye başlanır. Enfeksiyon taraması sırasında uygun protokollere göre koruyucu önlemler, izolasyon, yıkanma gibi uygulamalar yer almaktadır.


Trijaj değerlendirmesi subjektif ve objektif verilerden oluşmaktadır. Değerlendirme sırasında hastaların kendi anlatımları ile şikayetleri alınmaktadır. Hastaneye geliş şikayeti, en çok şikayet ettikleri semptom, ağrının şiddeti, travma mekanizması gibi durumlar sorgulanmaktadır. Objektif olan veriler gözle görünür yaralanma, lezyon, kanama,

öksürük gibi bulgular, ağrıya olan pozisyonel reaksiyonlar ve vital bulguları içermektedir. Bunlara ek olarak CTAS’da birincil ve ikincil modifikatörler tanımlanmıştır. Birincil modifikatörler solunum sıkıntısı, hemodinami, bilinç durumu, ateş, ağrının akut ya da kronik olması, kanama bozukluğu ve yaralanma mekanizması iken, ikincil modifikatörler şikayete göre ciddiyeti tanımlayan (örneğin göz travması, gözün kimyasal yanıkları) modifikatörlerdir (Davis et al. 2022). CTAS’da Kategori 1 resusitasyon gerektiren hastaları tanımlarken, Kategori 5 120 dakikaya kadar bekleyebilecek hastaları tanımlamaktadır.

2.1.4.3. ESI TRIYAJ SİSTEMİ (ESI)

Aciliyet şiddet indeksi (ESI) kaynak kullanımına yönelik geliştirilmiş algoritma tabanlı bir triyaj sistemidir (Baumann and Strout 2005; Gilboy et al. 2005; Chonde et al. 2013). Birinci seviye (ESI-1) hastanın yaşam kurtarıcı müdahale gerektirip gerektirmediği durumlar (kardiyopulmoner arrest, bilinç kapalı, ciddi solunum sıkıntısı, mental durum değişikliği, sıvı resusitasyonu gerekliliği, anafilaksi gibi), ikinci seviye (ESI-2) bekleyemeyecek durumdaki hastalar (göğüs ağrısı, inme, bilinç değişikliği, kemoterapi alan hastada ateş, stabil hemodinamili ektopik gebelik, gastrointestinal sistem kanaması, pnömotoraks), üçüncü seviye (ESI-3) birden fazla kaynak kullanımı gerektiren ve vital bulguları stabil (karın ağrısı, pnömoni, kırık şüphesi gibi) olan hastalar, dördüncü seviye (ESI-4) tek kaynak kullanımı gerektiren hastalar (idrar yolu enfeksiyonu, basit kesiler, bel ağrısı gibi), beşinci seviye (ESI-5) kaynak kullanımı gerektirmeyen hastalar (boğaz ağrısı, burun akıntısı gibi) olarak sınıflandırılmıştır. Şikayetler ve hastaların vital bulguları aciliyet seviyeleri kararında yeterli olmaktadır. Hastaların kaynak kullanımlarının tahmini

de olası öntanılara göre şekillendirilmektedir. ESI triyajına ait algoritma Şekil 1.1’de sunulmuştur(Gilboy et al. 2011)



Şekil 1.1. ESI triyaj işleyiş algoritması(Gilboy et al. 2011)

2.1.5. TRIYAJ VERİLERİ

2.1.5.1. BAŞVURU ŞİKAYETİ

Asıl başvuru şikayetleri (Chief complaints) verilerin uyumlu, maliyetsiz, standart kullanımı amacıyla Hastalık Kontrol ve Önleme Merkezleri (CDC) Ulusal Yaralanma Önleme ve Kontrol Merkezi tarafından oluşturulan spesifikasyon önerilerini kaydeden Acil Servis Departmanları için Elementler (DEEDS) V.1 listesinde “Hastanın veya hasta yakını tarafından kullanılanlara mümkün olduğunca yakın kelimelerle ifade edilen, ilgili metin açıklamasıyla birlikte kod veya tek başına metin açıklaması olarak girilen, hastanın bakım veya ilgi arama nedeni” olarak tanımlanmaktadır (Pollock et al. 1998).

Triyaj skalalarında da kendilerine ait başvuru şikayetleri listeleri oluşturulmuş, burada yapılandırılmış şikayetler aciliyet kategorileri ile ilişkilendirilmiştir (Grafstein, Unger, Bullard, Innes, et al. 2003; Grafstein et al. 2008; Veen et al. 2008)

2.1.5.2. VİTAL BULGULAR


Solunum, dolaşım gibi yaşamsal fonksiyonların ölçülebilir, sayısal şekline vital bulgular ya da yaşamsal bulgular adı verilmektedir (Lockwood et al. 2004a). En hayati standart vital bulgular kan basıncı (tansiyon), nabız (kalp hızı), solunum sayısı ve ateştir. Bunlar dışında bilinç durumu, oksijen saturasyonu, ağrı şiddeti, kan şekeri gibi diğer parametreler de vital bulgular olmaya aday ölçümler olarak gösterilmiştir (Lockwood et al. 2004b). Nabız, solunum sayısı gibi bulgular manuel olarak ölçülebilirken, tansiyon, ateş, oksijen saturasyonu gibi hayati fonksiyonların ölçümü bir cihaz kullanılarak ölçülebilmektedir.

Vital bulguların normal aralıkları yetişkin ve pediatrik yaş gruplarına göre değişmekle birlikte, hastaların kullandıkları ilaçlar, kronik hastalıkları gibi durumlar da vital bulguların normal aralıklarını etkileyebilmektedir (Heffernan et al. 2010).

CTAS ve ESI gibi triyaj algoritmalarının belirli bir kısmında vital bulguları da aciliyet belirlenmesinde kullanılmaktadır. CTAS için modifikatör olarak nabız, solunum sayısı ve sistolik kan basıncı kullanılırken, ESI triyajında ESI 2 ve ESI 3 arasındaki kararın verilmesinde yaşa göre solunum sayısı, kan basıncı ve oksijen saturasyonu ölçümleri kullanılmaktadır (Baumann and Strout 2005; Grafstein et al. 2008)

2.1.5.3. ÖNTANI

Hastalık tanısı koyma süreci hasta hekim karşılaşması ile başlamaktadır. Kanıta dayalı epidemiyolojik çalışmalardan elde edilen bulguların görülme sıklıkları göz önüne alınarak; hastanın ifadeleri ve bulgularına göre, en olası “öntanı” (working diagnosis, preliminary diagnosis, clinical diagnosis, provisional diagnosis) oluşturulur (Balogh et al. 2015). Bu öntanı bir ya da birden çok olabilir. En olası tanıların yanında listelenen diğer hipotez ya da olasılığa ait öntanılara ayırıcı tanılar (differential diagnosis) denir. Hastaya ait kesin bir tanı olmamakla birlikte ileri testler sonucunda kesin tanı (definitive diagnosis) oluşturulur (Balogh et al. 2015). Şekil 2.1’de örnek bir hasta bakım sürecine ait iş akışı gösterilmiştir.



Şekil 3.1 Hasta başvurusu sonrası örnek bir hasta bakım ve tanı oluşturma süreci

2.2. YAPAY ZEKA

Yapay zeka insanların zeka olarak adlandırılan öğrenme ve problem çözme gibi bilişsel fonksiyonlarını taklit eden sistemler olarak tanımlanmıştır (Grewal 2014). 1950 yılında Bilgisayar Mekanizması ve Zeka dergisinde yapay zekayı ortaya atmış olan ilk bilim insanı Alan Mathison Turing, Turing testi ile makinelerin insan gibi davranarak soruları yanıtlama özelliğini deneysel olarak araştırmıştır (Turing 2004). Daha sonra 1956 yılında

ABD Dartmouth Üniversitesi'nde Minsky ve McCarthy tarafından sibernetik alanından ayrışması amacı ile yapay zeka adını öne sürmüştür (Russell et al. 2010). Yapay zeka araştırmalarının robotik, görme, doğal dil anlama, konuşma, navigasyon, öğrenme, bilişsel modelleme, bilgi arama, bilgi üretme, bilgisayar arayüzü, problem çözme, oyun teorisi, optimizasyon gibi birden çok alt dalları bulunmaktadır.


2.2.1. VERİ MADENCİLİĞİ

Veri madenciliği terimi büyük miktarda veriden ya da veritabanlarından yararlı bilginin keşfi olarak tanımlanmaktadır (Zhou 2003) Rupnik ve ark. veri madenciliğini veriler arasında gizli kalmış daha önceden bilinmeyen örüntüleri ve ilişkileri ortaya koyan yararlı bilginin analiz süreci olarak tanımlamışlardır (Rupnik et al. 2007). 1700'lü yıllarda Bayes Teoremi ile başlayan veri madenciliği süreci, 1800'lü yıllarda regresyon analizi ile devam etmiştir. 1983 yılında Michael Lovell tarafından veri madenciliği adıyla kullanımı yaygınlaşmıştır (Denton 1985).

Veri madenciliğini uygulamalarının belirli basamakları vardır. Bunlar veri seçimi, ön işleme, transformasyon, veri madenciliği ve değerlendirme olarak tanımlanabilir. Veri madenciliğinin basamakları Tablo 2.1 ve Şekil 2.2.'de özetlenmiştir.

Tablo 2.1. Veri madenciliği basamakları

Basamak	Açıklama
1. Veri seçimi	Anlamlı sonuçlar için önemli veri kayıtlarının seçilmesi işlemidir.
2. Ön işleme	Seçilen veri kayıtlarının arasındaki gürültünün temizlenmesi, sistematik olarak bütünlüğünün sağlanması, örüntülere göre sadeleştirilmesi işlemidir.
3. Transformasyon	Temizlenen veri kayıtları veri madenciliği algoritmalarına göre uygun şekilde sayısallaştırılır ya da yapılandırılır
4. Veri madenciliği	Anormalliğin saptanması: Anormallik olup olmadığının taranması, saptanırsa çıkarılıp çıkarılmayacağı konusunun araştırılması İlişkisel kural öğrenme: Bağlantı kurmak için verinin özelliklerinin ilişkilerinin araştırılması, bağlantı varsa bu ilişkinin kullanılması Kümeleme: Gruplar ve yapıların benzerlik açısından incelenmesi Sınıflandırma: Çıkarılmış bilginin veriye uygulanması Regresyon: En az hata ortaya çıkaran fonksiyonların çıkarılması Özetleme: Sonuçların görselleştirilmesi ve başarı oranının gösterimi
5. Değerlendirme ve yorumlama	Sonuçların değerlendirilmesi



Şekil 2.2. Veri madenciliği iş akışı

Veri madenciliğinde uygun modelin seçimi çok önemlidir. Veri madenciliğinde modeller Tablo 2.2’de gösterilmiştir.

Tablo 2.2. Veri madenciliği modelleri

TANIMLAYICI	TAHMİN EDİCİ
Kümeleme	Sınıflandırma
Özetleme	Regresyon
İlişkilendirme	Zaman seri analizi
Sıra bulma	

2.3. DOĞAL DİL İŞLEME(NLP)

Doğal dil işleme (Natural language processing, NLP) dilbilim, yapay zeka ve veri bilimlerinin multidisipliner yaklaşımı ile insan dili ve bilgisayar dili arasındaki iletişimin sağlanmasını amaçlayan bilim dalıdır (Nadkarni et al. 2011). Doğal dil işleme insan dilinin işlenmesini konu aldığından metin madenciliği (text mining) ve konuşma tanıma (speech recognition) alanları NLP’nin içerisinde bulunmaktadır.

2.3.1. METİN MADENCİLİĞİ

Metin madenciliği yapılandırılmamış verilerden bilgi elde ederek kullanıcıların analiz ve karar vermesine yardım etmeyi amaçlamaktadır (Aggarwal and Zhai 2012). Veri madenciliği çerçevesinde veri olarak yapılandırılmamış veriyi yani metni kullanır ve yapılandırılmış bir çıktı elde etmeyi amaçlar (Seker 2015).

Amaç veri madenciliğinde olduğu gibi, metin içerisinde kelime ve köklerin bulunması, bunlara ait bilginin çıkarımı, kelimelerin frekans analizleri ve etiketlenmesi gibi yöntemlerle yapılandırılmış veriye ulaşma sağlanarak, sonuç tahmini (sınıflandırma, kümeleme), konu çıkarımı (entity recognition), özetleme ve ilişki kurma gibi sonlanımlara ulaşmaktadır (Dang and Ahmad 2014).

Metin madenciliğinin basamakları da veri madenciliğine benzerdir. Yapılandırılmamış verilerden bilgi toplanır, yapılandırılmış veriye çevrilir, yapılandırılmış veriden örüntü çıkarımı yapılarak analiz edilir ve gerekli bilginin çıkarımı sağlanır (Gaikwad et al. 2014; Dang and Ahmad 2014). Sırasıyla metin madenciliği çalışmalarındaki süreç aşağıdaki şekilde sürdürülmektedir (Patel and Soni 2012; Muischnek et al. 2018; Zhang et al. 2021).

1. Metin ön işleme: Yapılandırılmamış metinlerin belirli dil kurallarına göre yapılandırılması, etiketlenilmesi işlemidir. Metin içerisindeki bölümlerin ayrıştırılması, gürültünün azaltılması, normalizasyon ve yapılandırma işlemidir. Bu işlemler sırasında büyük küçük harflerin çevrimi, gereksiz boşluk, noktalama işaretleri ve anlam ifade etmeyen kelimelerin kaldırılması gerçekleştirilmektedir.

- a. Segmentasyon: Metni cümleler gibi kalıplarına ayırır.

- b. Tokenizasyon: Kelimelerin metin içerisinde bulunması işlemidir. Kelimeleri cümlelerin içerisinde ayırma süreci noktalama işaretlerinin, boşlukların çıkarılması ile elde edilmektedir
- c. Konuşma bölümlerinin etiketlenmesi (Part-of-speech tagging): Her kelime isim, fiil, sıfat gibi ögelere etiketlenir.
- d. Adlandırılmış varlık tanıma (Named entity recognition): Kavramlar insan, yer, kuruluş gibi isimler kategorize edilir.
- e. Özdeşlik çözümleme (Coreference resolution): Kategorize edilen varlıklara ait kelimelerin bulunması ve nesneye atıf yapılması ile gerçekleşir.
- f. Bağlılık ağrıştırması (Dependency parsing): Kelimeler arasındaki ilişkiler belirlenir.
- g. Semantik analiz: Metinden anlam çıkarma sürecidir.
- h. Durdurucu (“Stop words”) kelimelerin çıkarılması: Metinlerin işaret etiketlerinin, ve, ya da, veya bağlaçlarından arındırılması işlemidir.
- i. Köklerine ayırma (Stemming): Ayrılan kelimelerin köklerinin bulunması işlemidir. Böylelikle yapım ve çekim ekleri olmayan kökler ayırdedilerek, aynı içerikteki kelimenin farklı yapılandırılmış veri olmasının önüne geçilebilir.
- j. Lemmatizasyon (Lemmatization): Yapım ve çekim ekleri olan kelimelere ait kök kelimenin eşleştirilmesi işlemidir.

k. Konuşma etiketleme (Speech tagging): Kelimeleri fiil, nesne, zarf, özne gibi yapıları ile etiketleme işlemidir.

2. Metinden özellik çıkarımı: Temizlenen metinlerin sayısallaştırılmasıdır. Yapılandırılmamış metnin vektör ve sayılarla yapılandırılmasını içerir.

a. Bag of Words: Verisetinde kullanılan kelimelerin sıklıklarının belirlenmesi, ve metindeki varlığını ifade eder. Kelimelerin sırası yerine metinde kelimenin olup olmadığına göre vektöre dönüştürülür. Kelimeler aynı öneme sahiptir.

b. Terim frekansı-Ters belge frekansı: Kelimenin belgedeki önemi ve diğer belgelerdeki önemi frekans olarak belirtilir. Daha az yaygın kelimelerin sonuca olan etkileri daha fazla olabileceğinden ağırlıkları daha yüksek olabilmektedir.

c. Word2vec: Her kelime bir vektör olarak belirtilir. Anlamsal yakınlığı olan kelimeler yakın vektörlerle belirtilir.

3. Modelleme: Makine öğrenmesi modelleri ile metinden çıkarılacak sınıflara yönelik kümeleme ve tahmin algoritmaları uygulanır.

Metin Madenciliğine ait veri işleme teknikleri Tablo 2.3'te tanımlanmıştır.

Tablo 2.3. Metin madenciliğine ait veri işleme teknikleri

Bilgi getirimi	Metnin işlenerek aranılan yararlı bilginin bulunması işlemidir (Patel and Soni 2012; Dang and Ahmad 2014).
Bilgi çıkarımı	Bilgi çıkarımı anahtar kalıplar ve ilişkileri kullanarak yapılandırılmamış metnin analizini sağlar. Bunu daha önceden geçen dizileri aramak için örüntü eşleştirme, tokenizasyon, isim varlık tanıma, cümle segmentasyonunu içermektedir (Patel and Soni 2012; Gaikwad et al. 2014)
Kategorizasyon	Metnin denetimli öğrenme ile birden fazla kategorilendirilmesidir. Veri ön işleme indexleme, boyutsal küçültme ve sınıflandırmayı içermektedir (Patel and Soni 2012)
Kümeleme	Aynı içerikli dokümanların içerisinde grupların denetimsiz öğrenme ile bulunması olarak tanımlanmaktadır (Gaikwad et al. 2014; Dang and Ahmad 2014)
Görselleştirme	Metinlerdeki etiket ve kategorilerin yoğunluklarına göre görselleştirilerek sunulmasıdır (Gaikwad et al. 2014; Dang and Ahmad 2014).
Özetleme	Metnin anlamını kaybetmeden uzunluğunun ve detaylarının azaltılmasıdır (Gaikwad et al. 2014; Dang and Ahmad 2014) İstatistiksel ve dilbilgisel olarak önemli cümlelerin seçimi, paragrafların seçimi ile daha özet bir yapıya getirilerek, ana kavramların anlaşılmasını kolaylaştırır (Patel and Soni 2012)

Uygun metodun seçimi, metnin çeşitliliğine göre değişmektedir. Bilgi getirimi yapılandırılmamış metinler için uygunken, bilgi çıkarımı yapılandırılmış metinler için, özetleme yöntemi uzun ve detaylı metinlerin analizi için, kategorizasyon ise metin içeriğine göre daha önceden yapılandırılmış kategorilerin eşleştirilmesinde, kümeleme ise bilginin içerisindeki yapıların düzenlenmesi ve alt gruplara ayrılmasında kullanılmaktadır (Dang and Ahmad 2014).

4. Yorumlama ve değerlendirme: Metin madenciliği metodlarına ait sonuca ulaşmadaki performansları değerlendirilir.

Literatürde Doğal Dil İşleme Çalışmaları

Doğal dil işleme ve metin madenciliği son yıllarda tıp alanında yukarıdaki raporlama sistemlerini geliştirmeye devam ederken, şikayet verilerinden sonuç tahmini üzerine yapılan çalışmalarla acil tıpta da yerini almıştır (Travers and Haas 2003; Thompson et al. 2006a; Travers and Haas 2006; Lee et al. 2019a; Tootooni et al. 2019a). Acil servise başvuru anından itibaren alınan minimum verilerden hastaneye yatış/taburculuk, triyaj ve mortalite gibi sonuçların tahmin edilmesi literatürde önem kazanmıştır (Beitel and Mandl 2004; Kim et al. 2020; Kijpaisalratana et al. 2022).

Trijaj kararı sonrası mortalite tahmini özellikle triyajın bir altın standart olmaması nedeni ile yaygın olarak kullanılmaktadır(Klug et al. 2020; Fernandes et al. 2020a; Fernandes et al. 2020b). Klug ve ark. yapmış olduğu bir çalışmada 799,522 acil servis ziyareti ve 367,219 hastanın temsil ettiği (%0.6 mortalite) veri üzerinde ekstrem gradyan artırma(XGB) kullanılarak Şok Endeksi, Modifiye Şok Endeksi, 2 gün içindeki mortalite ve 2-30 gün arası mortalite incelenmiştir(Klug et al. 2020). Fernandes ve ark.. yapmış olduğu çalışmalarda, 235,826 yetişkin hastanın kaydı incelenmiş, lojistik regresyon, rastgele ormanlar ve ekstrem gradyan artırma uygulanmış. Model Manchester triaj ile karşılaştırılmış. 24 saat içinde hastanede ölüm veya kardiyopulmoner resusitasyon tahmini yapılmıştır. Triyaj verilerinden yatış kararının verilmesi ile ilgili çalışmalar da literatürde mevcuttur(Joseph et al. 2020; Ahmed et al. 2022b). Ahmed ve ark. 478,212 hastanın kaydı üzerinde taburculuk tahmini yapmış, ekstrem gradyan artırma, AdaBoost gibi makine öğrenmesi yöntemleri ile taburculuk ve yatış tahmin edilmiştir(Ahmed et al. 2022b). Acil servis hastaları üzerinde 445,925 yetişkin hastanın; 411,098 triaj verisi, 60,901 kritik hastalığı olan hastanın verileri incelenerek uygulanan sinir ağıları, ESI ve

vital bulgular kullanılarak 24 saat içerisinde kritik olay(mortalite, yoğun bakıma yatış tahminleri için kullanılmıştır(Joseph et al. 2020). Yine Sinir ağı regresyonunun uygulandığı 260,842 acil servis başvurusunda 5 seviye triyaj ve NLP yöntemleri ile karşılaştırılmış, hastaneye yatış veya taburcu edilme tahmini yapılmıştır(Sterling et al. 2019a). Yun ve ark. yaptığı bir çalışmada ise %4.6'sı kritik bakım gerektiren 80,433 acil servis başvurusundaki hastalarda sinir ağları ve ekstrem gradyan artırma modelleri KTAS ile karşılaştırılmış ve yoğun bakım ünitesine doğrudan yatış veya hastanede mortalite durumu tahmin edilmiştir(Yun et al. 2021). Trijaj verileri kullanılarak rastgele orman modeline ait yine bir çok kritik bakım, yatış ve taburculukta kullanıldığı çalışma görülmektedir(Levin et al. 2018b; Raita et al. 2019a; De Hond et al. 2021; Fenn, Davis, and Buckland 2021)

Birden çok doğal dil işleme modeli mevcuttur. Bu modellerin triyaj verisinden yatış tahminine yönelik yapılan tahmin performansının karşılaştırıldığı bir çalışmada 104,083 non-travma yetişkinlerin acil servis başvuruları ele alınmış ve logistik regresyon, kelime gömme ile derin sinir ağları, paragraf vektör ile derin sinir ağları, konu modelleme ile derin sinir ağları yatış tahmininde karşılaştırılmıştır(Chen et al. 2020).

Levin ve ark. 172,726 yetişkin acil servis hastası üzerinde E-triage uygulanmış, rastgele orman modelini ESI ile karşılaştırılmış. kritik bakım (mortalite veya YBÜ yatış), acil girişim ve hastaneye yatış durumu tahmini açısından karşılaştırılmıştır.

Çalışmanın hipotezi:

Literatürde derin sinir ağları ve diğer makine öğrenmesi yöntemleri ile metin madenciliği çalışmaları yapılmıştır fakat Türkçe şikayet verilerinden metin madenciliği ile öntanımlar ve acil servis triyaj kararı veren bir karar destek sistemi bulunmamaktadır. Bu yüzden çalışmanın literatüre ve klinik pratiğe girebilecek yeni bir yöntem olması beklenmektedir.

Hipotez:

1. Triage alınılan şikayet verilerinden metin madenciliği ile triyaj düzeyi (3 ve 5 düzey) tahmin edilebilir.
2. Triage verilerinden (şikayet ve vital bulgular) metin madenciliği ile olası öntanımlar tahmin edilebilir.
3. Triage verilerinden (şikayet ve vital bulgular) metin madenciliği ile sonlanım tahmin edilebilir.

Karar noktalarında acil servis çalışanlarına yardımcı kılavuz ve klinik skorlamalar olmasına karşın gerçek verilerle eğitilebilir, makine öğrenmesi ile karar verebilir bir karar destek sistemi bulunmamaktadır. Hekimin/triyaj personelinin belirli kurallara dayanarak verdiği kararlara yardımcı olabilecek, yapay zeka tabanlı bir karar destek sistemi olarak geliştirilebilir, hastane bilgi sistemine entegre edilebilir ya da kişisel mobil kullanım sağlanabilir bir sistem geliştirilmesi planlanmaktadır.

Böylelikle hasta bakım kalitesinin artması, hasta ile ilgili gereksiz tetkiklerin azaltılması dolayısı ile sağlık harcamalarının azaltılması, mortalite ve morbidite olasılığı yüksek

hastalıkların atlanmasının önüne geçilmesi, ve hasta bekleme süresinin de azalmasına yardımcı olacak uygulamalara yön vermeyi planlamaktayız.



3. GEREÇ ve YÖNTEM

Retrospektif olarak toplanan yapılandırılmış ve yapılandırılmamış verilerin makine öğrenmesi kullanılarak tahmin ve öngörü analizi gerçekleştirilecektir.

Bu çalışma 3 modül olarak planlanmıştır.

1. Yapılandırılmamış hasta şikayet metnlerinin Türkçe doğal dil işleme teknikleri ile veri ön işleme ve görselleştirilmesi
2. Makine öğrenmesi kullanılarak yapılandırılmış ve yapılandırılmamış verilerden 3 düzey triyaj (SB triyaj-Ek1), 5 düzey triyaj (ESI), öntanı ve sonlanım tahmini
3. En başarılı makine öğrenmesi yönteminin kullanıldığı bir karar destek sistemi oluşturulması

3.1 Verilerin toplanması

Çalışma 01.01.2019-01.07.2019 tarihleri arasında 3. basamak eğitim araştırma hastanesi acil servisine başvuran hasta verileri ile etik kurul ve veri kullanım izni alınmasını takiben hastane bilgi işlem biriminden elde edilmiş ve veri tablosuna kaydedilmiştir. Çalışma tarihleri süresince acil servise başvuran 18 yaş üzeri tüm hastalar çalışmaya alındı. Şikayet alanı boş olan, vital bulgulara ait verilerine ulaşılamayan, tekrarlanan başvuruları olan, şikayet verisi yerine konsültasyon notları içeren, ICD-10 kodu ve şikayet metni uyumsuzluğu saptanan(örneğin, kardiyak arrest tanı kodu olup burun akıntısı şikayeti ile gelen hasta), veri temizleme sonrası anlamsız veri kalan hastalar çalışma dışı bırakıldı.

Acil servise başvuran hastaların şikayet, laboratuvar, görüntüleme, konsültasyon, sonlanım, öntanı, triyaj düzeyi, nabız, oksijen saturasyonu, yapılan işlemlere ait veriler

hastane bilgi sisteminden alınarak Excel tablolama dosyası üzerine kaydedildi. Hastaların başvurusundaki laboratuvar, görüntüleme ve konsültasyon kullanım sayıları çalışma için önem arz etmediğinden dolayı her kaynağın kullanımı olmayan hastalar için “0”; kaynak kullanımı olan hastalar için “1” olarak kodlandı. Hastaların sonlanımları “taburcu” ve “yatış” olarak belirlendi. Hastaların şikayetlerine ait öntanılar ICD-10 kodları arasından şikayete yönelik öntanılar kör bir acil tıp uzmanı tarafından gözden geçirildi(Ek.2). Hastaların triyaj renk kodları hastane bilgi sisteminde bulunduğu hali ile “kırmızı” “sarı” ve “yeşil” olarak 3 şekilde belirtildi. ESI triyaj düzeyi ESI algoritmasında belirtildiği kurallara yönelik akış eşliğinde Şekil 3.1’de gösterilen ESI akış diyagramına göre 5 düzey olarak hesaplandı ve veriye ait hatalar bir acil tıp uzmanı tarafından kontrol edilmiştir.

Tablo 3.1 Verilerin analizine yönelik yapılacak işlemler

Değişken	Tür	Veri	İşlemler	
ID	Input	Sayısal-ordinal	-	
Şikayet	Input	Serbest Metin (Yapılandırılmamış)	Veri temizleme Tokenizasyon Metin madenciliği	
Laboratuvar	Input	Kategorik	ESI düzeyi saptama	0-Laboratuvar tetkiki kullanılmamış 1-Laboratuvar tetkiki kullanılmış
Görüntüleme	Input	Kategorik	ESI düzeyi saptama	0- Görüntüleme tetkiki kullanılmamış 1-Görüntüleme tetkiki kullanılmış
Konsültasyon	Input	Kategorik	ESI düzeyi saptama	0- Konsültasyon yapılmamış 1-Konsültasyon yapılmış
Sonlanım	Output	Kategorik	Tahmini yapılacak sonlanım	Yatış Vefat Taburcu
Triyaj Renk (Ek.1 Sağlık Bakanlığı triyaj renk kodları)	Output	Kategorik	Tahmini yapılacak sonlanım	Kırmızı Sarı Yeşil
Nabız	Input	Sayısal sürekli	0-300	
Oksijen	Input	Sayısal sürekli	0-100	
İlaç	Input	Kategorik	ESI düzeyi saptama	0-İlaç kullanılmamış 1-İlaç kullanılmış
Malzeme	Input	Kategorik	ESI düzeyi saptama	0-Malzeme kullanılmamış 1-Malzeme kullanılmış
ESI	Output	Kategorik	Tahmini yapılacak sonlanım	ESI 1 ESI 2 ESI 3 ESI 4 ESI 5

Öntanı	Output	ICD-10 kodları ile acil servis triyaj sonrası girilen öntanı/semptom kodları	Tahmini yapılacak sonlanım	
--------	--------	--	----------------------------	--

3.2. ESI düzeylerinin belirlenmesi ve şikayet verilerinin işlenmesi

ESI düzeylerinin açıklamaları Tablo 3.2’de verilmiştir.

Tablo 3.2. ESI düzeylerinin açıklamaları

ESI		Açıklama
1	Resusitasyon	Hemen acil hayati müdahale gerektiriyor (hava yolu, acil ilaçlar veya diğer hemodinamik müdahaleler (İV yol açılması, ek O ₂ , monitör, EKG veya laboratuvarlar bu müdahalelerden sayılmaz); ve/veya klinik durumlardan herhangi biri: entübe, apne, nabız yok, şiddetli solunum sıkıntısı, SpO ₂ <90, akut mental durum değişiklikleri veya tepkisiz)
2	Yüksek risk	Yüksek riskli durum (son kalan bir hasta sedyesine alacağınız hasta), ya da konfüze/letarjik/dezoryante ya da şiddetli ağrı/distres (klinik gözlem ya da ağrı skalasında 7 ve üzeri ağrı)
3	İkiden fazla kaynak gerektiren	Tek tek testleri veya röntgenleri değil, farklı türdeki kaynakların sayısı (örnekler: TKS, elektrolitler ve koagülasyon bir kaynağa eşittir; TKS ve göğüs röntgeni iki kaynağa eşittir)
4	Sadece bir kaynak gerektiren	
5	Kaynak gerektirmeyen	

Kısaltmalar: SpO₂ = Oksijen saturasyonu; TKS = Tam kan sayımı

Verisinde yer alan hasta şikayet metinleri, vital bulgular ve kaynak değişkenleri kullanılarak ESI düzeyinin belirlenmesi 3 şekilde yapıldı:

1. Hastanın kendi kaynak kullanımından elde edilen gerçek hasta verilerinden belirlenmesi

- Örnek olarak belirli ilaç, malzeme kullanımı olan (Adrenalin/atropin/defibrilatör kullanımı = ESI 1) hastanın uygun ESI düzeyinin tanımlanması
- Konsültasyon, görüntüleme ya da laboratuvar kullanım sayısı ile ESI 4 ya da 5 daha üst ESI düzeyi olduğuna karar verilmesi


2. ESI algoritmasına göre hastaların ESI seviyelerinin belirlenmesinde kullanılacak kurallar oluşturulması (Ek.2).

3. Kör bir acil tıp uzmanı tarafından ESI kural tabanlı şikayetler ve vital bulgulara göre ESI belirlenmesi

Tablo 3.3. Hastaların kaynak, malzeme, ilaç kullanımlarına göre ESI düzeylerinin belirlenmesine ait kurallar (Ek.2)

ESI 5	Kaynak kullanımı yok	Laboratuvar, görüntüleme, konsültasyon, malzeme, işlem verileri 0 olan VE taburcu olan (VEYA yatış ya da vefat olmayan) VE ICD-10 öntanısı ESI 1 ve 2 içerisinde belirtilmiş tanıları içermeyen (kardiyak arrest, solunum yetmezliği...vb)
ESI 4	Bir kaynak kullanımı mevcut.	Laboratuvar, görüntüleme, konsültasyon, malzeme, işlem verilerinden HERHANGİ BİRİ 1 (VE DİĞER HEPSİ 0) olan VE taburcu olan (VEYA yatış ya da vefat olmayan) VE ICD-10 öntanısı ESI 1 ve 2 içerisinde belirtilmiş tanıları içermeyen (kardiyak arrest, solunum yetmezliği...vb)
ESI 3	Birden fazla kaynak kullanımı mevcut	Laboratuvar, görüntüleme, konsültasyon, malzeme, işlem verilerinden EN AZ 2'si 1 olan VE ICD-10 öntanısı ESI 1 ve 2 içerisinde belirtilmiş tanıları içermeyen (kardiyak arrest, solunum yetmezliği...vb) VE NABIZ <100 VE SpO ₂ >92
ESI 2	Yüksek riskli durumlar	NABIZ >100 VE/VEYA SpO ₂ <92 VE Laboratuvar, görüntüleme, konsültasyon, malzeme, işlem verilerinden EN AZ 2si 1 olan VE ICD-10 öntanısı ESI 1 ve 2 içerisinde belirtilmiş tanıları içermeyen (kardiyak arrest, solunum yetmezliği...vb) VE Hayati müdahale girişimlerine sahip OLMAYAN hastalar (Tüp torakostomi, kardiyopulmoner resusitasyon, entübasyon vb)
ESI 1	Acil müdahale gerektiren durumlar	ICD-10 öntanısı ESI 1 ve 2 içerisinde belirtilmiş tanıları içeren (kardiyak arrest, solunum yetmezliği...vb) VE Hayati müdahale girişimlerine sahip OLAN hastalar (Tüp torakostomi, kardiyopulmoner resusitasyon, entübasyon vb)

ESI kurallarının olduğu akış şeması Şekil 3.1’de belirtildiği gibi düzenlenmiştir.



Şekil 3.1. ESI triyaj düzeylerini belirlemede kullanılan algoritma akış diyagramı

Kuralların oluşturulması sürecinde hastaların gerçek ESI seviyeleri belirlenmiş olup ESI sütununa işlenmiştir. Hekim tarafından gruplar halinde sonlanımlar ve ICD kodları ile eşleştirilerek yine de yanlış satırlar varsa çalışmadan çıkarılacak böylelikle yanlış kararın önüne geçilmesi sağlanmıştır. Örneğin “Adrenalin kullanılan, göğüs ağrısı ICD kodu olan hasta ESI 5 olamaz”.

Yanlış malzeme girilmesi, malzeme girilmemesi gibi nedenlerden dolayı kaynak kullanımına ait çıkarımların yapılamaması ve gereksiz tetkik istenmiş olabilme ihtimali ile (o anda hekimin kararı kan testi istemek gibi) retrospektif olarak yapılan çıkarımın yanlış olabilmesi bu konudaki kısıtlılıkları oluşturmaktadır. Buna rağmen yeşil hastalarında ESI 1 kategorisi varlığı mevcuttur. Bunun nedeni hastaların ESI 5 olmalarına rağmen kırmızı alandan giriş yapmaları olabilir.

Metin önişleme için R Studio 2022 12.0 , Microsoft 365 Excel tablolama programı ve KNIME 4.1.5 programları kullanılmıştır.

Hastaların şikayetlerine ait veriler hastane bilgi sistemindeki “şikayet” serbest metin kutularından elde edildi. Bu metin kutularının içerisinde vital bulgulara ait tekrarlı veriler, konsültasyon notları, fizik muayene bulguları, ve diğer notlar olması nedeni ile şikayete ait veriler dışındaki gereksiz veriler belirlenerek temizlendi. Tıbbi kısaltmalara ait liste oluşturuldu ve standartlar belirlenerek kelimeler düzeltildi (Ek.3).

Tablo 3.4. Orjinal ve kısaltılmış örnek şikayet metni

Anamnez serbest metin kutusundan alınan metin	Analize alınacak olan örnek şikayet metni
Ateş: 36.7 Nabız: 61 Oksijen Satürasyon: 96 Bilinç Durumu : Belirtilmedi EKG: ŞİKAYETİ: • ÖYKÜ: 3 GÜNDÜR BOĞAZ AĞRISI OLAN HASTA AYAKTAN ACİL SERVİSE BAŞVURDU. ÖZGEÇMİŞ: Ameliyat: Alerji: Bilinen yok İlaçlar: FİZİK MUAYENE: GENEL DURUM: İyi • GÖRSEL AĞRI SKORU (0-10): (1-2 Hafif, 3-4 Huzursuz, 5-6 Üzüntülü, 7-8 Şiddetli, 9-10 Dayanılmaz) NÖROLOJİK: GKS (E4 M6 V5) (3-15): 15 Bilinç: Normal Mental Durum: Koopere ve oryante Pupiller: İzokorik IR: +/+ Nistagmus: Yok Kraniyal Sinirler: Doğal Ense Sertliği, Kernig, Brudzinski: Yok	3 gündür boğaz ağrısı olan hasta ayaktan acil servise başvurdu.

Motor ve Duyu Muayenesi: Motor ve Duyu defisit saptanmadı Fasiyal Asimetri: Yok DTR: Normal Babinski: -/- Serebellar Testler: (Dismetri, Disadiadokinezi, Romberg, Ataksi): Normal BAŞ-BOYUN: Boyunda LAP/Kitle: Yok Saç ve Saçlı Deri: Doğal Karotis Üfürümü: Yok KBB: Orofarenks: HİPEREMİK Tonsiller: Doğal Uvula: Doğal Dış Kulak Yolu: Timpan Membran: Temporomandibular Eklem: Doğal Tragus Hassasiyeti: Yok GÖZ MUAYENESİ: Eksternal Göz Yapıları: Haricen doğal Görme Alanı: SOLUNUM SİSTEMİ MUAYENESİ: Her iki hemitoraks solunuma eşit katılıyor Aksesuar solunum kasları solunuma katılmıyor Solunum sesleri doğal, ral-ronküs duyulmadı KARDİYOVASKÜLER: JVD: Yok Siyanoz: Yok PTÖ: -/- Periferik Nabızlar: Eşit palpabl ve açık Kapiller Dolum Süresi: Normal Kalp Sesleri: Doğal ve ritmik Ek Ses (S3,S4, Frotman-Klik-Mekanik Kapak Sesi)-Üfürüm: Yok ABDOMEN: Bağırsak Sesleri: Normoaktif Abdominal Üfürüm: Yok Ele Gelen Kitle veya pulsasyon: Yok Distansiyon: Yok ASSİT düşündüren Matite: Yok HSM: Yok Hassasiyet: Yok Defans: Yok Rebound: Yok RT: Fıtık Muayenesi: Fıtık saptanmadı	
---	--

GENİTOÜRİNER: KVAH: -/- Genital Muayene Yapılmadı EKSTREMİTE: Anormal hareket, deformite saptanmadı Extremiteler arası ısı, renk ve çap farkı izlenmedi Dört ekstremitte aktif hareketli; duyu, motor ve dolaşım muayenesi doğal Homans: -/- CİLT MUAYENESİ: Döküntü, ekimoz, peteşi-purpura görülmedi • DİĞER:	
---	--

Tablo 3.5. Örnek cümlelerle metin önışleme

Segmentasyon	3 gündür olan baş ağrısı mevcut. Bulantı ve kusma eşlik etmiyormuş	• 3 gündür olan baş ağrısı mevcut. • Bulantı ve kusma eşlik etmiyormuş.	
Tokenizasyon	3 gündür olan baş ağrısı mevcut. Bulantı ve kusma eşlik etmiyormuş	• 3 • Gündür • Olan • Baş • Ağrısı • Mevcut • Bulantı • Kusma • Eşlik • Etmeyormuş	
“Stop words” çıkarılması	3 gündür olan baş ağrısı mevcut. Bulantı ve kusma eşlik etmiyormuş	3 gündür olan baş ağrısı mevcut. Bulantı ve kusma eşlik etmiyormuş	
Stemming	3 gündür olan baş ağrısı mevcut. Bulantı ve	• gündür-gün • ağrısı-ağrı • bulantı-bulan • kusma-kus	

	kusma eşlik etmiyormuş		
Lemmatizasyon	3 gündür olan baş ağrısı mevcut. Bulantı ve kusma eşlik etmiyormuş	• ağrısı • ağrımıyor • ağrımış • ağrması AĞRI	

Metin madenciliğine ait veri ön işleme işlemleri “tidyverse”, “tm”, “SnowballC”, “textmineR” paketleri kullanılarak R Studio üzerinden gerçekleştirildi. Veri kümesindeki metin, bir "Corpus" (metin koleksiyonu) haline getirilip bu Corpus'da tüm metinler küçük harflere dönüştürülmüştür. Ayrıca, belirli "stopwords" (Türkçe'de anlam taşımayan “ve”, “veya”, “ya da” vb sözcükler) belirlendi ve Corpus'tan çıkarıldı. Medikal terimler ve kısaltmaları içeren bir "lookup" dosyası oluşturuldu ve bu dosya, verisetindeki belirli terimlerin düzeltilmesi için kullanıldı (Ek.4). Veriseti daha sonra metni daha kolay analiz edilebilir hale getirmek için sözcüklerin frekanslarını ölçmek ve bu frekansları içeren bir n-gram çerçevesi oluşturmak için "tm" ve "RWeka" kütüphaneleri kullanıldı. Oluşturulan bu frekans tablosu, sonraki adımlarda kullanılmak üzere verisetine eklendi.

Sonuçların görselleştirilmesinde "wordcloud" ve "ggplot2" kütüphaneleri kullanılarak bir kelime bulutu ve frekans grafiği oluşturulmuştur.

3.3. İstatistiksel ve makine öğrenmesi ile tahminsel Analiz

Çalışmamızda R Studio 2022.12.0 ve KNIME (Konstanz Information Miner) platformları üzerinden tahminsel analizler gerçekleştirildi. KNIME açık kaynak kodlu Java platformu kullanan metin görüntü ve veri analizlerinin yapılabildiği bir çapraz platformdur. 2004

yılında Konstanz Üniversitesi bünyesinde geliştirilen bu platformda veri analizi iş akışları üzerinden kurulmaktadır. İş akışlarının modellenmesi nodlar ve bağlantıları üzerinden yapılmaktadır. Bu nedenle çalışmamızda Zemberek gibi Türkçe Dil işleme araçlarının da kullanılabilir olduğu bir platform olan KNIME ve R platformları seçilmiştir(Gerdan 2019; KNIME). Literatürde geliştirilmiş farklı açık kaynak Türkçe doğal dil işleme kütüphaneleri bulunmaktadır (Yılmaz et al. 2021).

Doğal dil işleme (NLP) teknikleri, verilerin makine öğrenmesi algoritmalarına uygun bir formata dönüştürülmesi için kullanılmıştır. Bu amaçla, şikayet metinleri üzerinde ön işleme adımları gerçekleştirilmiştir. Veriler öncelikle küçük harfe çevrilmiş ve özel karakterler ile sayılar kaldırılmıştır. Ardından, metinlerin içerisindeki kelimeleri çiftler halinde birleştiren bigramlar oluşturulmuştur.

Yapılandırılmamış şikayet verilerinin ön işlemesi tamamlandıktan ve ESI seviyeleri, triyaj renk kodları ve öntanılar belirlendikten sonra tahminsel analiz makine öğrenmesi modelleri kullanılarak yapılmıştır. Makine öğrenmesi modellerinden Random Forest, Extrem Gradyan Arttırma(XGB) ve iki katmanlı sinir ağları (two layer neural network) seçilmiştir.

XGB, bir çok zayıf karar ağacının bir araya gelerek daha güçlü bir model oluşturduğu sınıflandırma ve regresyon yöntemidir(Chen and Guestrin 2016). Her karar ağacının gradyan arttırmasını optimize ederek tüm modelin performansını arttırma yöntemidir. Rastgele orman yine çok sayıda karar ağacını bir araya getirerek daha güçlü bir tahmin modeli oluşturan bir algoritmadır(Qi 2012). XGB ağaçları hataları düzeltmek için her yeni ağaç oluşumunda önceki ağaçlara bağlı iken, random forest bağımsız ağaçlar oluşturmakta,

tahminleri ortalama yada çoğunluk oyu ile bir sonuca vardırır(Qi 2012; Chen and Guestrin 2016) Overfitting ve eksik verilerin ön işlenmesi rastgele orman için bir dezavantaj olsa da, rastgele ormanda ağaçların bağımsızlığı paralel işlemeye uygundur.

İki katmanlı sinir ağları, bir giriş katmanı, bir gizli katman ve bir çıktı katmanı olmak üzere üç katmandan oluşan bir yapay sinir ağıdır. Rastgele orman gibi aşırı öğrenmeye daha duyarlıdır.

Makine Öğrenmesine ait XGB, Rastgele orman ve iki katmanlı sinir ağlarına yönelik R kodları Ek.4'te verilmiştir. İlk olarak, XGBoost modeli eğitilmiştir. Çoklu sınıfların sınıflandırılmasında kullanılan softmax fonksiyonunu kullanarak birden çok sınıf arasında bir olasılık dağılımı elde etmesi nedeni ile bu yöntemi seçtik. ESI sınıf tahmininde num_class 5, Triyaj sınıf tahmininde num_class 3, öntanı tahmininde num_class 6 olarak belirlenmiştir. Bu model, 70:30 eğitim ve test veri setleri için oluşturulmuş ve performansı "multi:softmax" hedef fonksiyonu kullanılarak ölçülmüştür. Softmax aktivasyon fonksiyonu çıktıların toplamı 1 olacak şekilde, çıktıları olasılık dağılımına dönüştürür Bu da her sınıf için olasılık değerlerini elde etmemizi sağlar.

$$\text{softmax}(x)_i = \exp(x_i) / \sum \exp(x_j)$$

Çok sınıflı sınıflandırma görevlerinde genellikle kullanılan kayıp fonksiyon kategorik çapraz entropi kaybıdır. Çıktı ve modelin tahminleri arasındaki farkı ölçer ve gerçek çıktıları ne kadar yakın olduğunu belirler. Yanlış tahminler için logaritmik olarak daha yüksek hata payı vererek ilerler.

$$L = -\sum (y_i * \log(p_i))$$

Optimizasyon için kullandığımız bir diğer yöntem kök ortalamaasının karesinin yayılımıdır(RMSProp). RMSprop, modelin ağırlıklarını güncellemek için kullanılan bir optimizasyon algoritmasıdır. Modelin ağırlıklarını ve biaslarını verilerden öğrenir. Her bir ağırlığın güncelleme hızını, geçmiş gradyanların karelerinin hareketli ortalamaasına bölerek kendi hızını da dinamik olarak ayarlar.

$$E[g^2]_t = 0.9 * E[g^2]_{t-1} + 0.1 * g_t^2$$

$$\theta_t = \theta_{t-1} - \text{learning_rate} * g_t / \sqrt{E[g^2]_t + \epsilon}$$

Yapay Sinir Ağları (YSA) modeli kullanılarak bir başka sınıflandırma Keras kütüphanesi kullanılarak eğitilerek gerçekleştirilmiştir. Doğrultulmuş doğrusal birim aktivasyon fonksiyonu bir nöronun aktivasyonunu kontrol eden bir fonksiyondur. Giriş 0'dan büyük olması durumunda girişi olduğu gibi çıktı olarak verir. Giriş ≤ 0 ise çıktı olarak 0 verir. Bu aktivasyon fonksiyonunun avantajı gradientin kaybolma problemini çözmesi ve hızın artırılması olması nedeni ile çalışmada kullanılmıştır.

$$f(x) = \max(0, x)$$

Kullanıcı arayüzü tasarımı için Shiny kütüphanesi kullanılmıştır. Shiny, R dilinde web uygulamaları geliştirmek için kullanılan bir pakettir. Kullanıcının girdiği şikayet metnini alarak doğal dil işleme fonksiyonlarına giriş olarak kullanmaktadır. Çalışmamızda geliştirdiğimiz karar destek sistemi Rshiny modeli üzerinde oluşturulan makine öğrenmesi ve interaktif bir kullanıcı arayüzünden(metin girişi, tahmin sonucu, tahmin performansını görüntüleme) oluşmaktadır.

3.4. R Shiny ile karar destek sisteminin oluşturulması

The screenshot displays the R Shiny decision support system interface. At the top, there is a browser address bar showing '127.0.0.1:5536'. Below this, the interface is divided into three main sections:

- ESI Prediction:** This section has a text input field labeled 'Enter the complaint:' containing the text 'senkop göğüs ağrısı olan hasta'. Below the input field is a 'Predict' button. To the right of the input field, the predicted ESI is shown as '1'. Below this, a list of predicted terms is displayed: '[1] "senkop göğüs" "göğüs ağrısı" "ağrısı olan" "olan hasta"'. Further down, the model's performance metrics are listed: 'Train accuracy: 0.92', 'Test accuracy: 0.52', 'Train Sensitivity: NA', and 'Train Specificity: NA'.
- ontani Prediction:** This section has a text input field labeled 'Enter the complaint:' containing the text 'göğüs ağrısı nefes darlığı ile acil servise başvurdu'. Below the input field is a 'Predict' button. To the right of the input field, the predicted ontani is shown as '2'. Below this, a list of predicted terms is displayed: '[1] "göğüs ağrısı" "ağrısı nefes" "nefes darlığı" "dar" [5] "acil servise" "servise başvurdu"'. A horizontal scrollbar is visible below the list.
- ontani Prediction:** This section has a text input field labeled 'Enter the complaint:' containing the text 'karın ağrısı kabızlık ile gelen hasta'. Below the input field is a 'Predict' button. To the right of the input field, the predicted ontani is shown as '3'. Below this, a list of predicted terms is displayed: '[1] "karın ağrısı" "ağrısı kabızlık" "kabızlık gelen" "gelen t"'. A horizontal scrollbar is visible below the list.

Figure 3.2. R Shiny karar destek sistemi

Metin madenciliği, önişleme ve metin analizi için KNIME Analytics Platform v4.5.1 ve R Studio uygulaması kullanılmıştır).


Tanımlayıcı ve istatistiksel analiz için IBM SPSS Statistics 27, tahmin ve öngörü analizi için Weka 3.9, R Studio ve SPSS 27 paket programları kullanılmıştır.

Triyaj ve öntanı tahminlerinin sensitivite, spesifisite, pozitif prediktif değer, negatif prediktif değer, F-skorları analizleri sonrası tahmin doğrulukları hesaplandıktan sonra doğruluğu yüksek olan öngörücü yöntem ile RShiny üzerinde karar destek sistemi arayüzü yapılmıştır.

4. BULGULAR

2018 Ocak- 2019 Temmuz ayları arasında acil servise başvuran toplam 534.265 hasta kaydından, hastane bilgi sisteminden alınan verilerine tam olarak ulaşılabilen 54.867 hasta kaydı analize alındı.

Hasta dahil etme kriterlerine yönelik akış diyagramı Şekil 4.1’de sunulmuştur.



Şekil 4.1 Çalışmaya dahil etme kriterleri

4.1. YAPILANDIRILMIŞ VERİLERİN ANALİZİ


54.867 hasta verisi analize alındı. Hastaların %70,1’inde laboratuvar istemleri yapılmış, %31,1’ine görüntüleme yapılmış, %22,8’ine konsültasyon istenmiş olduğu saptandı. Hastaların %57,7’sinde ilaç ve %54,4’ünde malzeme kullanımı yapılmıştı (Tablo 4.1). Hastaların triyaj kategorilerinin dağılımına bakıldığında en çok sarı alan (%76,4) olduğu,

ESI triyaj kararlarının dağılımında da en çok ESI 3 olduğu görüldü. Hastaların %6,3 oranında yatış olduğu saptandı. En çok kaydedilen 3 tanının akut batın (%14), üst solunum yolu enfeksiyonu (%10,3) ve diyare (%6) olduğu saptandı. Hastaların ortalama nabız değeri 89 (IQR 24); ortalama oksijen saturasyonları 97 (IQR 3) olarak saptandı. Nabız ve oksijen saturasyonu ESI 2 ve ESI 3 ayırımında kullanılmasından dolayı ESI 2 ve ESI 3 arasında nabız ($p=0.000$) ve oksijen saturasyonu ($p<0.001$) açısından istatistiksel olarak anlamlı bir fark mevcut olup, ESI 2’de anlamlı olarak nabız daha yüksek ve oksijen saturasyonu daha düşük saptanmıştır.

Yapılandırılmış değişkenler		n (%)
Laboratuvar		38.485 (%70,1)
Görüntüleme		17.083 (%31,1)
Konsültasyon		12.519 (%22,8)
Sonlanım	Taburcu	51.389 (%93,7)
	Yatış	3478 (%6,3)
Trijaj	Kırmızı	5301 (%9,7)
	Sarı	41.939 (%76,4)
	Yeşil	7627 (%13,9)
Kaynak Kullanımı	İlaç	23.216 (%42,3)
	Malzeme	31.651 (%57,7)
ESI	1	28 (%0,1)
	2	12.742 (%23,2)
	3	27.553 (%50,2)
	4	8241 (%15,0)
	5	6303 (%11,5)

Tablo 4.1. Yapılandırılmış değişkenlerin sayı ve dağılımları

Öntanılara ait sayılar ve dağılım Ek.5’de gösterilmiştir. ESI ve triyaj renk skorlarının dağılımı Şekil 4.2’de gösterilmiştir.



Şekil 4.2. ESI ve triyaj renklerine göre dağılım grafiği

Trijaj renklerine göre ESI kategorileri arasında istatistiksel olarak anlamlı fark saptanmıştır ($p=0.000$). ESI 1 kategorisinde yeşil hasta bulunmamakta iken, ESI 5 kategorisinde 103 kırmızı hasta olduğu saptanmıştır. ESI düzeylerinin triyaj renk kodlarına göre dağılımları Tablo 4.2’de gösterilmiştir. ESI kategorilerine göre taburculuk ve yatış arasında istatistiksel anlamlı fark saptanmıştır ($p < 0.001$).


Tablo 4.2. 3’lü ve 5’li triyaj (ESI) kategorilerine göre hasta dağılımları

ESI	Kırmızı	Sarı	Yeşil
1	19	9	0
2	995	11581	162
3	2228	24821	479
4	1956	4649	1630
5	103	879	5356
Toplam	5301	41939	7627

İkili n-gramlar içerisinde en sık kullanılan semptom çifti karın ağrısı, göğüs ağrısı, baş ağrısı ve boğaz ağrısı olarak saptandı (Şekil 4.3 ve Şekil 4.4).



Şekil 4.3. Şikayet metinlerinde en sık kullanılan bigramlara ait kelime bulutu



Şekil 4.4. En sık kullanılan kelimelere ait n-gram grafiği

1. TRİYAJ TAHMİNİ

- XGB ile yapılan triyaj tahmininde toplam doğruluk 0,77 (%95 CI 0,7629-0,777) olarak saptandı. Spesifisiteler en yüksek kırmızı (0,999) ve yeşil (0,998) sensitivite ise en yüksek sarı triyaj kategorisinde gözlemlendi.
- Random Forest ile doğruluk 0,7651 (%95CI 0,7599-0,7729) olarak saptanmıştır. Ancak Kappa değeri 0,034 olarak bulunmuştur. Yine XGB’de olduğu gibi en yüksek sensitivite sarı alanda (0,993) gözlenirken, spesifisite en yüksek kırmızı (0,997) ve yeşilde (0,996) olduğu saptanmıştır.
- Sinir ağırları algoritmasının yaptığı tahminlerde de başarı oranı 0,7664 (%95CI 0,7599-0,7729) olurken Kappa 0.03 olarak saptandı. En yüksek

sensitivite sarı alanda (0,993) bulundu. Yine kırmızı (0,997) ve yeşil (0,996) tahminlerinde spesifisite daha yüksekti (Tablo 4.3 ve Tablo 4.4).

Tablo 4.3 Üçlü triyaj tahminlerine ait çapraz tablolar

Trijaj 3'lü Crosstab	Referans (n)			
		Kırmızı	Sarı	Yeşil
Xgboost	Kırmızı	0	3	0
	Sarı	1337	10533	1797
	Yeşil	0	18	29
Random Forest	Kırmızı	30	39	3
	Sarı	1545	12505	2205
	Yeşil	4	49	80
Yapay Sinir Ağları	Kırmızı	55	100	8
	Sarı	1512	12395	2180
	Yeşil	12	98	100

Tablo 4.4 Üçlü triyaj tahminlerinin sensitivite, spesifisite, PPV, NPV, doğruluk ve kappa değerleri

Trijaj üçlü Performans metrikleri		Sensitivite	Spesifisite	Ppv	Npv	Doğruluk	Kappa
Xgboost	Kırmızı	0,000	0,999	0,000	0,902	0,77 (%95 cı 0,7629-0,777)	0,0125
	Sarı	0,998	0,009	0,770	0,580		
	Yeşil	0,015	0,998	0,617	0,868		
Random forest	Kırmızı	0,018	0,993	0,416	0,905	0,766 (%95 cı 0,759-0,772)	0,038
	Sarı	0,993	0,030	0,769	0,570		
	Yeşil	0,034	0,996	0,601	0,864		
Yapay Sinir Ağları	Kırmızı	0,034	0,992	0,337	0,906	0,762 (%95 cı 0,755-0,768)	0,048
	Sarı	0,984	0,045	0,770	0,469		
	Yeşil	0,043	0,992	0,476	0,865		

2. ESI TAHMİNİ

- XGB ile yapılan tahminlerde en yüksek sensitivite ESI 3 düzeyinde (0,964) gözlemlendi. Toplam doğruluk 0,512 (%95CI 0,504-0,520) olarak saptandı. Kappa değeri 0,06 olarak bulundu. Spesifisiteler ESI 3 haricinde 0,971 ve üzerinde saptandı.
- Random Forest ile doğruluk 0,512 olarak saptanmıştır. Ancak Kappa değeri 0,06 olarak bulunmuştur. En yüksek sensitivite ESI 3'te gözlenirken 0,964, spesifisite ESI 3 hariç hepsinde 0,97 ve üzeri saptanmıştır.
- Sinir ağırları algoritmasının yaptığı tahminlerde de doğruluk 0,342 (%95 CI 0,333-0,351) olarak saptandı. Sensitivite düzeyleri düşüktü 0,000-0,473. ESI 1 ve ESI 5 tahminlerinde spesifisite daha yüksekti (sırasıyla 0,964 ve 1,000) (Tablo 4.5 ve Tablo 4.6).

Tablo 4.5 ESI triyaj tahminlerine(ESI) ait çapraz tablolar

ESI		Referans				
Crosstab		1	2	3	4	5
Xgboost	1	0	0	0	0	0
	2	0	78	79	12	15
	3	10	3554	7988	2388	1536
	4	0	4	2	8	1
	5	0	200	179	53	354
Random Forest	1	0	0	0	0	0
	2	0	126	111	19	20
	3	8	3555	7953	2384	1502
	4	0	6	6	7	2
	5	0	180	176	55	351
Yapay Sinir Ağları	1	0	81	198	63	27
	2	0	557	995	223	122
	3	3	1212	2599	791	570
	4	3	689	1692	431	215
	5	0	0	0	0	0

Tablo 4.6. Beşli triyaj tahminlerinin(ESI) sensitivite, spesifisite, PPV, NPV, doğruluk ve kappa değerleri

		Sensitivite	Spesifisite	Ppv	Npv	Doğruluk	Kappa
ESI Performansları							
Xgboost	1	0,000	1,000	Na	0,999	0,512	0,062
	2	0,020	0,991	0,423	0,769	(%95 cı 0,504-0,519)	
	3	0,968	0,088	0,516	0,736		
	4	0,003	0,999	0,533	0,850		
	5	0,185	0,970	0,450	0,900		
Random Forest	1	0,000	1,000	Na	0,999	0,512	0,066
	2	0,325	0,988	0,456	0,768	(%95 cı 0,504-0,520)	
	3	0,964	0,932	0,516	0,723		
	4	0,002	0,998	0,333	0,850		
	5	0,187	0,971	0,460	0,902		
Yapay Sinir Ağları	1	0,000	0,964	0,000	0,999	0,342	-0,002
	2	0,219	0,831	0,293	0,768	(%95 cı 0,333-0,351)	
	3	0,473	0,483	0,502	0,455		
	4	0,285	0,719	0,142	0,855		
	5	0,000	1,000	Na	0,910		

3. ÖNTANI TAHMİNİ

Tüm öntanılar 6 kategorik gruba ayrılmıştır.

1. Kardiyovasküler aciller (Akut miyokard infarktüsü, Aort diseksiyonu, Abdominal aort rüptürü; Aritmi, Pulmoner tromboemboli vb)
2. Gastrointestinal Aciller (Akut batın, ileus, Safra yolları ve safra kesesi patolojileri, Pankreatit)
3. Solunumsal Aciller (Kronik obstrüktif akciğer atağı, Astım atağı, Solunum yetmezliği)
4. Nörolojik Aciller (Serebrovasküler hastalık, Subaraknoid kanama, Epilepsi, Menenjit)
5. Gebelik komplikasyonları

6. Diğer

- a. XGB ile öntanılar arasında kardiyovasküler öntanılar tahmini için doğruluk 0,005 (%95CI 0,004-0,006) olarak saptanmıştır. Kappa değeri - 0,008 olarak bulunmuştur. En yüksek sensitivite 0,635 ile solunumsal aciller öntanısı tahmininde saptanmıştır. Spesifisite gebelik komplikasyonları hariç tüm sınıflarda 0,865 ve üzerinde saptanmıştır.
- b. Random Forest ile doğruluk 0,005 (%95CI 0,004-0,006) olarak bulundu. Sensitivite en yüksek 63,5% ile gebelik komplikasyonları, spesifisite de gebelik komplikasyonları hariç tümünde 0,865 ve üzerinde saptanmıştır.
- c. Sinir Ağları ile doğruluk 0,034 kappa -0,016 olarak saptanmıştır. Yine en yüksek sensitivite 0,065 ile solunumsal acillerin tahmininde, en yüksek spesifisite de 0,964 ile nörolojik acillerin tahmininde saptanmıştır (Tablo 4.7 ve Tablo 4.8).

4. SONLANIM TAHMİNİ

54.867 hastanın 3487'si (%6,35) servis ya da yoğun bakım ünitesine yatırıldı. Hasta sayısının dengesiz olması nedeni ile XGBOOST ve Random forest ile tahmin geçerli sonuç vermedi fakat iki katmanlı yapay sinir ağları ile yapılan sonlanım tahmininde doğruluk 0,931 (%95CI 0,927-0,935), kappa 0,105; Sensitivite 0,99, Spesifisite 0,07 olarak saptandı.

Tablo 4.7 Öntanı tahminlerine ait çapraz tablolar

Öntanılar crostab	Referans						
		1	2	3	4	5	6
Xgboost	1	19	1405	0	9	28	528
	2	0	0	0	0	0	0
	3	25	12	0	688	3	262
	4	0	0	0	0	0	0
	5	938	1675	65	585	54	9284
	6	0	0	0	0	0	0
Random Forest	1	2090	31	46	34	1	646
	2	36	4762	0	19	41	835
	3	0	0	4	0	0	0
	4	36	22	0	1734	3	386
	5	0	0	0	0	48	0
	6	1564	2178	87	1206	118	22479
Ysa	1	262	1235	11	218	37	2500
	2	43	109	0	47	6	412
	3	861	931	31	755	18	3785
	4	26	78	2	29	1	311
	5	127	195	4	49	5	629
	6	0	0	0	0	0	0

Tablo 4.8. Öntanı tahminlerinin sensitivite, spesifisite, PPV, NPV, doğruluk ve kappa değerleri

Öntanılar Performansları		Sensitivite	Spesifisite	Ppv	Npv	Doğruluk	Kappa
Xgboost	1	0,019	0,865	0,009	0,929	0,004 (%95 cı 0,003-0,005)	-0,008
	2	0,000	1,000	0,000	0,801		
	3	0,000	0,936	0,000	0,995		
	4	0,000	1,000	0,000	0,917		
	5	0,635	0,190	0,004	0,989		
	6	0,000	1,000	0,000	0,353		
Random forest	1	0,560	0,978	0,727	0,954	0,817 (%95 cı 0,813-0,821)	0,624
	2	0,681	0,970	0,836	0,931		
	3	0,029	1,000	0,996	0,996		
	4	0,579	0,987	0,795	0,965		
	5	0,227	1,000	1,000	0,996		
	6	0,923	0,633	0,813	0,826		
Ysa	1	0,198	0,648	0,061	0,874	0,034 (%95 cı 0,031-0,037)	-0,016
	2	0,042	0,950	0,176	0,798		
	3	0,645	0,498	0,004	0,997		
	4	0,026	0,964	0,064	0,912		
	5	0,074	0,920	0,004	0,994		
	6	0,000	1,000	0,000	0,399		

4. TARTIŞMA

Yaptığımız bu çalışmada triyajdan elde edilen şikayet metinlerinden metin madenciliği ile triyaj, sonlanım (hastaneye yatış/taburculuk) ve öntanı tahmini yapan bir model oluşturup, makine öğrenmesi yöntemlerinden Xgboost, Random Forest ve iki katmanlı sinir ağları modelleri karşılaştırıldı. Sonlanım tahmininde en başarı method yapay sinir ağları iken, en yüksek sensitivite sarı ve ESI 3 tahminlerinde saptanmıştır.

Acil tıp doğası gereği başvuru şikayetlerine ait verilere dayanmaktadır. Acil servise gelen hastaların başvuru şikayeti, hastaların kendi dillerinde söyledikleri olarak tanımlanabileceği gibi, hekimlerin hastanın söylediklerinden çıkarım yapması olarak da tanımlanabilir (Schneider et al. 1979). Şikayet sadece tanıya götüren bir veri olmayıp, triyaj kararında, progresyonun belirlenmesinde, kötüleşmenin gösterilmesinde, hastaneye yatış ya da taburculuk kararında kullanılan bir değişkeni de tanımlamaktadır. Acil servise başvuran hastalarda bazen tek, bazen birden fazla şikayet vardır. Hatta bazı hastalar acil serviste zaman zaman şikayetlerini yeterince anlatamamaktadır (Nemec et al. 2010). Bilinç değişikliği veya genel durumun kötüleşmesi durumunda acil servis şikayetleri ile değil, hekimin triyaj ekibi tarafından görülen ve tarif edilen durum nedeniyle başvururlar.

Bu varyasyonlardan dolayı acil servis profesyonelleri tarafından başvuru şikayetleri kategorize edilmeye çalışılmıştır (Thompson et al. 2006b; Lee et al. 2019b; Tootooni et al. 2019b). Böylece hastaların şikayet gruplarının kategorilerine göre standardize edilmesi, triyaj düzeylerinin varyasyonlardan etkilenmemesi ve şikayet verilerinin etkin bir şekilde toplanarak hasta bakımının iyileştirilmesi mümkün olabilecektir.

Birleşik Krallık Ulusal Sağlık Sistemi (NHS), hastane öncesi alandan aldığı şikayetlere dayalı olarak bir başvuru nedenleri listesi geliştirmiştir (Schneider 1979). Kanada acil tıbbi bilgi sisteminin kurulması için kendi oluşturdıkları ve geliştirdikleri triyaj sisteminin temelini oluşturan pediatri, gebelik vb. özel grupları içeren bir başvuru şikayetleri listesi oluşturulmuştur (Grafstein, Unger, Bullard, Innes, et al. 2003; Grafstein et al. 2008).

Triyaj skalaları, hastaların aciliyetini belirlemek ve hangi hastanın hekim tarafından daha önce değerlendirilmesi gerektiğini en hızlı şekilde belirlemek için geliştirilmiş araçlardır (Baumann and Strout 2005; Veen et al. 2008; Unger et al. 2010; Than et al. 2014; Funakoshi et al. 2016; Kwon et al. 2019; Raita et al. 2019a). Triage skalalarının çoğu başlıca şikayetleri kullansa da Acil Şiddet İndeksi (ESI), aciliyet durumunu belirlemek için kaynak kullanımını içeren bir algoritma kullanmaktadır (Gilboy et al. 2005).


Mortalite, taburculuk, yoğun bakım ünitesine yatış gibi sonuçları tahmin etmek için kullanılan minimum ziyaret kaydı 80.433 (Yun et al. 2021) ve maksimum başvuru 799,522 olarak görülmektedir (Klug et al. 2020). Literatürde triyaj verilerinden makine öğrenmesi ile en sık karşılaştırılan triyaj modeli ESI'dir (Levin et al. 2018a; Raita et al. 2019a; Klug et al. 2020; Fernandes et al. 2020a; Joseph et al. 2020; Fenn, Davis, and Buckland 2021). Beş çalışma hospitalizasyon ve yoğun bakım ünitesine yatışı tahmin etmiş (Parker et al. 2019; Sterling et al. 2019b; Chen 2020; De Hond et al. 2021; Ahmed et al. 2022a). Şikayet verilerinin dışında en sık kullanılan değişkenler demografik veriler, vital bulgular, ve vardiye tipi olarak kullanılmıştır.

Literatürde şikayet ve triyaj verilerinden sonlanım tahmininde en sık kullanılan model XGB (Raita et al. 2019a; Klug et al. 2020; Fernandes et al. 2020a; Fernandes et al. 2020b;

Joseph et al. 2020; De Hond et al. 2021; Yun et al. 2021; Ahmed et al. 2022b) lojistik regresyon (Parker et al. 2019; Sterling et al. 2019; Raita et al. 2019b; Fernandes et al. 2020a; Fernandes et al. 2020b; Chen 2020; Joseph et al. 2020; De Hond et al. 2021) ve RF (Raita et al. 2019b; Fernandes et al. 2020a; Fernandes et al. 2020b; De Hond et al. 2021; Fenn, Davis, and Buckland 2021) olarak karşımıza çıkmaktadır. Bu nedenle çalışmamızda bu modelleri ele aldık. Sadece dört modelde derin öğrenme kullanılmıştır(Raita et al. 2019a; Chen 2020; De Hond et al. 2021; Yun et al. 2021).

En iyi tahmin ediciler

Hastaneye yatış ve taburculuk kararının belirlenmesinde en sık kullanılan değişkenler yaş, cinsiyet, acil servise geliş türü (ambulans ya da ayakta), vital bulgular (nabız, sistolik ve diyastolik kan basıncı, oksijen saturasyonu, vücut sıcaklığı ve solunum sayısı), komorbid hastalıklar ve yapılandırılmış ya da yapılandırılmamış şikayet verilerinden oluşmaktaydı (Şekil 5).



Şekil 5. Literatürde kullanılan çalışmalardaki değişkenlerin dağılımı

Fernandes ve ark. tarafından yoğun bakım ünitesine yatış için tanımlanmış en iyi prediktörler nabız, oksijen saturasyonu, solunum sayısı ve sistolik kan basıncı olarak belirlenmiştir (Fernandes et al. 2020a). Literatürde yapılan bir çalışmada vital bulgulara ek olarak Glasgow Koma skorunun da yaşlı hastalarda daha iyi predikte edebileceği gösterilmiştir (Barfod et al. 2012). Fenn ve ark. yoğun bakım ünitesine yatış kararındaki en önemli 5 değişken olarak yaş, hematokrit, beyaz küre, acil servis taburculuk sayısı ve ESI skoru olarak bulmuştur (Fenn, Davis, and Buckland 2021). Önem sıralamasında Ahmed et al en iyi değişkenleri oksijen saturasyonu, yaş, solunum sayısı, vücut kitle indeksi ve şikayet verisi olarak bulmuştur (Ahmed et al. 2022b). Fernandes et al da Glasgow Koma skoru; ağrı skoru, nabız, varış türü olarak saptamışlardır (Fernandes et al. 2020b).

Doğal dil işleme çalışmalarında en önemli diskriminantlar “ağrı”, “ani başlangıç”, “düşük oksijen”, “şiddetli ağrı”, “karın ağrısı”, “senkop”, “baş ağrısı” ve “pnömoni” olarak bulunmuştur (Fernandes et al. 2020a) Fernandes ve arkadaşlarının yaptığı başka bir araştırmada ise en iyi 5 diskriminant “çok düşük oksijen saturasyonu”, “anormal kalp hızı”, “riskli havayolu”, “etkisiz solunum” ve “bilinç değişikliği” olarak saptanmıştır (Fernandes et al. 2020b). Joseph ve arkadaşları yatış tahmininde verilen parametreler arasında en iyi diskriminant olarak ESI skorunu göstermiş, kritik olmayan hastalarda metinde ise “ateş” ve “göğüs ağrısı” olarak saptanmıştır (Joseph et al. 2020). Sadece yapılandırılmış verilerle NN 0,81 AUC ortaya çıkarırken, şikayet metinleri eklendiğinde bu değer 0,85’e yükselmiştir (Joseph et al. 2020).

Çalışmamızda en sık kullanılan kelimeler içerisinde “karın ağrısı”, “göğüs ağrısı”, “baş ağrısı”, “boğaz ağrısı” ve “ağrısı yok” en iyi diskriminantlar olarak saptanmıştır.

Yapılandırılmamış verilerin eklenmesi ile şikayetlerden doğal dil işleme kullanılarak yapılan tahminlerde LR 0.95, RF 0.94 XGB 0.96 AUC ile başarılı performans sergilemiştir (Fernandes et al. 2020b). Sözcük ayrımının ötesinde, Sterling ve ark. ana şikayet metinlerinin NLP’sinin 3 yöntemini karşılaştırmıştır: kelime torbası (bag of words), paragraf vektörleri (paragraph vectors) ve konu dağılımı (topic distribution) arasında paragraf vektörlerinde taburculuk için en iyi NPV 0.87 ve en iyi AUC 0.78 olarak saptanmıştır (Sterling et al. 2019b). Çalışmamızda biz de doğal dil işleme yöntemi olarak n-gram tabanlı yaklaşımı tercih ettik. Chen ve ark, DNN ile kelime gömme modelinin en iyi AUC’yi (0.875) gerçekleştirdiğini göstermiştir. Paragraf vektör modele göre yatış tahmininde ise spesifisite %84 ve NPV %90.32 olarak gösterilmiştir.

Triyaj tahmininde makine öğrenmesi modellerindeki performanslara bakıldığında Fernandes ve ark. tarafından ESI ve MTS ile karşılaştırıldığında en iyi AUC ve AUPRC ile tahmin eden model lojistik regresyondur (Fernandes et al. 2020a) ve referans ESI ile karşılaştırıldığında ESI 3 hastalarında daha yüksek duyarlılık oranı saptanmıştır (Fernandes et al. 2020a). Değişkenlere ESI değerleri de eklendiğinde tahmin olasılığı daha yüksek bulunmuştur (Fernandes et al. 2020a). Hatta triyaj skorlarının ilk iki seviyesi YBÜ'ye yatış için daha iyi prediktörken, makine öğrenmesi modeli karar verilmesi zor hasta grubu olan 3. seviye grubundakilerin tahmininde daha iyi sonuç vermiştir. Makine öğrenmeleri ise kendi aralarında karşılaştırıldığında sırasıyla en iyi performanslar LR, RFR ve XGB olarak sıralanmıştır (Fernandes et al. 2020a). Levin ve ark. yapmış olduğu bir çalışmada ESI tahmini 0.92 ile DNN daha iyi doğruluk ile diğer makine öğrenmesi modellerinden daha yüksek bir performans sergilemiştir (Levin et al. 2018b). Yun ve arkadaşlarının yaptığı bir çalışmada MTS ile de karşılaştırıldığında LR daha iyi performans göstermiştir (0.83 vs 0.79) (Yun et al. 2021). Bu çalışmada da makine öğrenmesi modelleri değerlendirildiğinde XGB'nin, DNN'ye göre daha yüksek AUC değerine sahip olduğu görülmüştür (0.86 vs 0.83) (Yun et al. 2021). Chen ve arkadaşları referans modelle karşılaştırıldığında yatış tahmininde en yüksek AUC değerine sahip metodun DNN (0.87 ve 0.82) ve LR (0.76) (0.683) olduğunu saptanmıştır (Chen 2020). De Hond'un yaptığı çalışmada triyajda yatış tahmininde en yüksek AUC değerine sahip model XGB olarak saptanmıştır (0.84). Bunu DNN (0.83), LR (0.82) ve RF (0.80) takip etmiştir (De Hond et al. 2021). Ahmed et al geleneksel XGB, ADAB ve MLP modellerini tabu search ile geliştirerek T-XGB, T-ADAB ve T-MLP modelleri üretmiş ve sırasıyla AUC değerleri 0.93, 0.95 ve 0.83 olarak saptanmıştır (Ahmed et al. 2022b) Mortalite tahmini için kullanılan ML modellerinde, geleneksel skarlama sistemlerine göre daha

yüksek tahmin başarısı saptanmıştır (0.96 ve 0.92) (Klug et al. 2020). Joseph ve ark yaptığı çalışmada yatış tahmininde XGB 0.82, NN 0.81 iken, LR 0.80 olarak saptanmıştır. Fernandes ve ark. bir diğer çalışmasında sadece klinik verilerle LR 0.93, RF 0.95, XGB 0.96 performansını tahmin etmişlerdir (Fernandes et al. 2020b). Raita ve ark. yapılandırılmış klinik veriler ve kategorik şikayet verileri ile kritik bakım tahmini için referans modelin AUC değerini 0.74 bulurken, RF(0.85), XGB DT(0.85), DNN(0.86) daha yüksek olarak saptamış ve hospitalizasyon kararı için ise aynı modellerin AUC değerleri sırasıyla 0.69, 0.81, 0.82, 0.82 olarak saptanmıştır (Raita et al. 2019b). Yun ve ark. yaptığı çalışmada da referans KTAS'a göre (0.796) XBG (0.861) ve DNN (0.833) daha iyi kritik bakım ihtiyacı olan hastaları tahmin edebildiği gösterilmiştir (Yun et al. 2021).

Lee ve ark. yapmış olduğu bir çalışmada MNB ve DVM, LSTM ve GRU RNNs kullanılarak sonlanımı ICD-9/10 kodu ve taburculuk tahmini yapılmıştır (Lee et al. 2019b). LTSM sınıflandırması en iyi performans olarak bulunmuştur (F1 0.96). Şikayet verileri kullanıldığından GRU en iyi performans olarak bulunmuştur (F1=47.38). Bazı öntanıların saptanması daha kolayken bazı tanıların daha zor saptandığı belirtilmiştir (Lee et al. 2019c).

Horng ve ark. (Horng et al. 2017) sepsis tanısını koymada yapılandırılmamış şikayet verileri, vital bulgular ve hemşire kanaatinin olduğu notlar DVM ile tahmin için kullanılmıştır. Eğri altında kalan alan vital ve demografik bilgilerle 0.67 iken, şikayet verileri, vital bulgular ve demografik bilgilerle 0.84 olarak bulunmuştur. Sadece serbest metinlerin analizinde ise 0.89 olarak saptanmıştır.

Heinz ve ark tarafından demografik veriler, özgeçmiş ve diğer klinik verilerin olduğu yapılandırılmamış metinlerin doğal dil işleme yöntemi ile hastalıkların tahmininde kullanılmıştır. Elektronik sağlık kayıtlarından elde edilen verilerin cerrahi yara yeri enfeksiyonu tahmininde metin madenciliği yöntemi ile araştırılmış ve başarı oranı %100 olarak bulunmuştur (Heinze et al. 2001).

Literatürde büyük dil modelleri ile iletişim, sosyal medya, bilgisayar mühendisliği ve bilimleri, sosyal sanatlar gibi farklı alanlarda kullanılan sohbet robotları ve konuşma araçları mevcuttur. Bunlardan en çok bilinenler OpenAI firmasının piyasaya çıkardığı GPT ve ChatGPT versiyonları ve Google firmasının ortaya çıkardığı Bert ve Bard isimli uygulamalardır (Rahaman et al. 2023).

Bu sohbet robotları, özellikle COVID-19 pandemisi sırasında eğitim, ruh sağlığı, doğum ve kronik hastalıklar gibi çeşitli tıbbi durumlar için taranması ve teşhisi için kullanılmıştır (Ghosh et al. 2018; He et al. 2022; Tzelios et al. 2022; King 2022; Kittipimpanon et al. 2022; Kim et al. 2023).

Çeşitli çalışmalar, sohbet robotlarının tıbbi uzmanlık ve teşhisi yapmada yüksek doğruluk oranları elde etmesine yönelik araştırmalar yürütmüştür. Örneğin, bir çalışma chatbot'un en iyi tahmin, en iyi ikili ve üçlü tahmini için 0.70'in üzerinde doğruluk oranları elde ettiğini bulmuştur (Kim et al. 2023). Başka bir çalışmada ise, 10 hasta senaryosunun ChatGPT-3 ile tanı koymadaki tahminlerinde doğruluk oranları %83,3 ve %53,3 olarak bulunmuştur (Hirosawa et al. 2023).

Ayrıca, sohbet robotlarının performanslarının triyaj ve tanı kararları için öngörülen sonuçlar listesi oluşturularak artırılabilceği ve özellikle tek bir cevap beklenildiğinde %51 gibi daha düşük oranlarda doğruluk bildirilmiştir (Ceney et al. 2021). Büyük doğal dil modelleri ile tıbbi alanlarda yapılan çalışmalar kısıtlı olmakla birlikte, tıbbi verilerle

eğitilme amacı güdülmese bile, chatbot'ların tıbbi teşhis ve triyaj kararlarında sağlık hizmeti sunucularına yardımcı olma potansiyeline sahip olduklarını, ancak yeteneklerinin ve sınırlamalarının tam olarak anlaşılması için daha fazla tıbbi veri ve karşılaştırma çalışmalarına ihtiyaç olduğu ortaya çıkmaktadır.

Çalışmamızdaki kısıtlılıkların en önemli nedeni hastane bilgi sisteminden alınan acil servise başvuran 534.265 hastadan verilerine erişilebilir 54.867 hastanın analize alınabilmesiydi. Bu veriler içerisinde hastaların ilk triyaj verilerine erişilebilme oranı %10.2 olarak saptandı. Yeterli tıbbi kayıtların olmaması makine öğrenmesinin önünde büyük bir engel teşkil etmektedir. Acil servislerin hızlı süreçlerle ilerlemesi ve yeterli sayıda veri kayıt personelinin olmaması hekimlerin hasta bakım sürecinde veri kaydı konusundaki zaman ayırabilmesini engellemektedir. Veri kaydı için gerekli zaman ya da personel sağlama dışında veri kayıtları konusunda gerekli eğitimin verilmesi, Türkçe dil karakterleri ve noktalama işaretlerine dikkat edilmesi gerekmektedir. Çünkü doğal dil işlemede noktalama işaretleri, tokenizasyon, segmentasyon gibi süreçleri etkilemektedir. Bu nedenle tıp fakülteleri ya da sağlık bilimleri fakültelerinde tıbbi kayıt tutma eğitimi verilmesi bu sorunu çözebileceğini düşünmekteyiz.

Diğer bir kısıtlılık da verisetimizin dengesiz olmasıdır. Kırmızı, ESI 1 ve yatış oranı çalışmamızda oldukça düşük olarkmıştır. Bu durum literatürde de F skoru etkileyebileceği düşünülmektedir (Fernandes et al. 2020a). Bunun nedeni verilerine erişilebilir hastaların dağılımının acil servis triyaj alanı sıklıkla sarı ve yeşil hastalar için kullanılmaktadır. Kardiyak arrest, bilinç durumu kötü, solunum sıkıntısı yaşayan hastalar her ne kadar triyaj alanından geçmeden direk kırmızı alana girse de, tüm başvuruları aldığımızda geliş vital bulguları, geliş şikayeti yazılamadan alanlarda müdahaleye başlanması gerçek hayat sürecinde verilerin bu hastalarda eksik olmasına neden

olmaktadır. ESI 1 kararı çok hızlı verilebilirken , ESI 2-3-4 kararı vermek triyaj çalışanları için daha kompleks olmaktadır. Çalışmamız sonuçları daha çok sarı alan ve ESI 2-3-4'e yönelik olarak tanımlanabilir. ESI 1 kategorisinde yeşil hasta bulunmamakta iken, ESI 5 kategorisinde 103 kırmızı hasta olduğu saptanmıştır. Bunun nedeni baştan yanlış girilmesi olabileceği gibi, kırmızı alandaki hastaların direk yatırılması ile herhangi bir kaynak kullanımının sisteme girilmemesinden dolayı da olabilir. Ayrıca yüksek riskli grupların yoğun bakım tahmini de seçim yanlılığı gösterebilmektedir(Fernandes et al. 2020a) Fenn et al zamansal değişimlerin de sonuçları etkileyebileceğini göstererek, gerçek zamanlı tüm verilerin ele alındığında ya da yatışların arttığı dönemlerle makine eğitildiğinde farklı sonuçlar verebileceğini belirtmişlerdir (Fenn, Davis, Buckland, et al. 2021). Bu nedenle hasta seçimi ve veri dağılımı sonuçları etkileyebildiği için başvuran tüm hasta verileri toplanmasına rağmen düzensiz dağılım sonuç üzerinde bir kısıtlılık oluşturabilmektedir.

Yine triyaj kararı triyaj personeli tarafından verildiğinden triyaj personelinin deneyimi, eğitimi standart ESI algoritması gibi algoritması olmayan süreçlerde farklılık gösterebilmektedir. Bu nedenle triyaj personeli farklılıkları güvenilirlik analizi kullanarak model performansı ile karşılaştıran ileri çalışmalara ihtiyaç duyulmaktadır.

Bunun yanı sıra acil servise yatış için gelen hastaların yatırılması ya da triyaj alanında yoğunluk nedeni ile tüm vital bulguların aktarılamaması nedeni ile de veri kaybı olmaktadır. Kağıt tabanlı sistemden bilgisayar tabanlı sisteme geçiş dönemi aralığı da hasta gözlem formlarından bilgisayara şikayet verilerinin aktarımında aksaklığa neden olmaktadır. İkinci bir kısıtlılık anamnez serbest metin alanı yetkili kişilere açık olması, hasta bakım süreci içerisinde muayane bulgularını barındırması, ilk açılan ekranda olması nedeni ile ek notların da bu alana kaydedilmesi ile triyaj verileri, muayene verileri, anamnez verilerini de içermesi nedeni ile metin olarak karmaşık ve temizlenmesi uzun

süre almaktadır. Bunların içinden fizik muayene verileri farklı hekimler tarafından farklı şablonlarla girilmesi nedeni ile ilgili şablonun temizlenmesi, şablon içerisinde değişiklik yapılması nedeni ile silinmeyen muayene verilerinin olması da metin önişleme sürecini zorlaştırmaktadır.

Diğer bir kısıtlılık Türkçe doğal dil işleme paketlerinin sağlık verilerine uyarlanabilirliği, kısaltmaların karşılıklarının belirlenmesine ihtiyaç vardır. Örneğin veri temizleme sürecinde “RT” kısaltması bazı yerlerde “rektal tuşe” olarak geçerken bazı yerlerde “radyoterapi” olarak saptanmıştır. Bu nedenle terminolojinin ve kısaltmaların doğru kullanımına ve Türkçe medikal doğal dil işleme kütüphanelerinin geliştirilmesine ihtiyaç vardır.

Kısıtlamalardaki bir diğer nokta, prediktörlerin değişkenliğidir. Yapılandırılmış ve yapılandırılmamış ana şikayetlerin yanı sıra, literatürde başvuru zamanı, etnik köken, sevk türü vb. gibi tahmin performansını değiştiren diğer faktörlerin de sonlanım tahmininde etkilidir (Fernandes et al. 2020a; Fenn, Davis, Buckland, et al. 2021). Uzun zaman aralığında alınan verilerde yeniden başvuruların da göz önüne alınması gerekmektedir. 6 yıllık veri içerisinde aynı gün ya da 24 saat içerisindeki tekrar başvurular da sonlanım kararını etkileyebilir. Literatürde yapılan çalışmalarda makine öğrenmesi yöntemlerinde hiperparametre optimizasyonu, iterasyon sayısı, kalibrasyon ve interpretation farklılıkları da bulunmakta olup çalışmamızda bu konular yüksek veri ve kısıtlı işlemci sorunları nedeni ile yapılamamıştır. Klinik karar destek sistemlerinin gerçek verilerle öğrenmesi ve optimizasyonunun sağlanabilmesi için hız ve performansı daha yüksek donanımlara ihtiyaç duyulmaktadır.

5. SONUÇ ve ÖNERİLER

Yapılandırılmamış şikayetler ile triyaj kararını vermede üç yöntemin de tahmin hassasiyetleri sarı ve ESI 3 hastaları için yüksek olurken, sonlanımda sinir ağları daha başarılı bulunmuştur. Öntanılar gebelik komplikasyonları haricindeki tüm tanılar için %86 ve üzerinde saptanmış olup, modellerin tahmin performanslarına yönelik daha yüksek sayıda veri ile validasyon çalışmalarına ihtiyaç bulunmaktadır. Gerçek yaşam verilerinin doğruluğu kadar, karar destek sistemlerinde kullanılan doğru verisetine özgü makine öğrenmesi seçimi de önem kazanmaktadır. Veri kayıtları konusunda eğitimin arttırılması ile tıbbi verilerin doğru ve tam olması hedefine ulaşılabileceğini ve Türkçe medikal veriler ile yapılan doğal dil işleme konusunda artacak çalışmalar ile model performanslarının da artabileceğini düşünmekteyiz.

6. KAYNAKLAR

Aggarwal CC, Zhai C. 2012. An Introduction to Text Mining. In: Mining Text Data. Boston, MA: Springer US; p. 1–10. https://doi.org/10.1007/978-1-4614-3223-4_1

Ahmed A, Ashour O, Ali H, Firouz M. 2022a. An integrated optimization and machine learning approach to predict the admission status of emergency patients. *Expert Systems with Applications*. 202:117314. <https://doi.org/10.1016/j.eswa.2022.117314>

Balogh EP, Miller BT, Ball JR, Committee on Diagnostic Error in Health Care, Board on Health Care Services, Institute of Medicine, The National Academies of Sciences, Engineering, and Medicine. 2015. Diagnostic Process. In: Improving Diagnosis in Health Care [Internet]. Washington, D.C.: National Academies Press; [accessed 2021 Dec 24]; p. 32–33. <https://doi.org/10.17226/21794>

Barfod C, Lauritzen MMP, Danker JK. 2012. Abnormal vital signs are strong predictors for intensive care unit admission and in-hospital mortality in adults triaged in the emergency department - a prospective cohort study. *Scand J Trauma Resusc Emerg Med*. 20:28. <https://doi.org/10.1186/1757-7241-20-28>

Baumann MR, Strout TD. 2005. Evaluation of the Emergency Severity Index (version 3) triage algorithm in pediatric patients. *Academic Emergency Medicine*. 12(3):219–224. <https://doi.org/10.1197/j.aem.2004.09.023>

Beitel AJ, Mandl KD. 2004. Use of Emergency Department Chief Complaint and Diagnostic Codes for Identifying Respiratory Illness in a Pediatric Population. *Pediatric Emergency Care*. 20(6):6.

Bullard MJ, Musgrave E, Warren D. 2017. Revisions to the Canadian Emergency Department Triage and Acuity Scale (CTAS) Guidelines 2016. CJEM. 19(S2):S18–S27. <https://doi.org/10.1017/cem.2017.365>

Bullard MJ, Unger B, Spence J, Grafstein E. 2008. Revisions to the Canadian Emergency Department Triage and Acuity Scale (CTAS) adult guidelines. CJEM. 10(02):136–142. <https://doi.org/10.1017/S1481803500009854>

Ceney A, Tolond S, Glowinski A, Marks B, Swift S, Palser T. 2021. Accuracy of online symptom checkers and the potential impact on service utilisation. Wilson FA, editor. PLoS ONE. 16(7):e0254088. <https://doi.org/10.1371/journal.pone.0254088>

Chen C-H. 2020. Emergency department disposition prediction using a deep neural network with integrated clinical narratives and structured data. International Journal of Medical Informatics. 139:104146. <https://doi.org/10.1016/j.ijmedinf.2020.104146>

Chen C-H, Hsieh J-G, Cheng S-L, Lin Y-L, Lin P-H, Jeng J-H. 2020. Early short-term prediction of emergency department length of stay using natural language processing for low-acuity outpatients. The American Journal of Emergency Medicine. 38(11):2368–2373. <https://doi.org/10.1016/j.ajem.2020.03.019>

Chen T, Guestrin C. 2016. XGBoost: A Scalable Tree Boosting System. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining [Internet]. San Francisco California USA: ACM; [accessed 2023 Jul 19]; p. 785–794. <https://doi.org/10.1145/2939672.2939785>

Chonde SJ, Ashour OM, Nembhard DA, Kremer GEO. 2013. Model comparison in Emergency Severity Index level prediction. *Expert Systems with Applications*. 40(17):6901–6909. <https://doi.org/10.1016/j.eswa.2013.06.026>

Considine J, Levasseur SA, Villanueva E. 2004. The Australasian Triage Scale: Examining emergency department nurses' performance using computer and paper scenarios. *Annals of Emergency Medicine*. 44(5):516–523. <https://doi.org/10.1016/j.annemergmed.2004.04.007>

Dang S, Ahmad PH. 2014. Text Mining: Techniques and its Application. *IJETI International Journal of Engineering & Technology Innovations*. 4.

Davis S, Ju C, Marchandise P, Diagne M, Grant L. 2022. The Effect of Human Supervision on an Electronic Implementation of the Canadian Triage Acuity Scale (CTAS). *The Journal of Emergency Medicine* [Internet]. <https://doi.org/10.1016/j.jemermed.2022.01.014>

De Hond A, Raven W, Schinkelshoek L, Gaakeer M, Ter Avest E, Sir O, Lameijer H, Hessels RA, Reijnen R, De Jonge E, et al. 2021. Machine learning for developing a prediction model of hospital admission of emergency department patients: Hype or hope? *International Journal of Medical Informatics*. 152:104496. <https://doi.org/10.1016/j.ijmedinf.2021.104496>

Denton FT. 1985. Data Mining as an Industry. *The Review of Economics and Statistics*. 67(1):124. <https://doi.org/10.2307/1928442>

Fenn A, Davis C, Buckland DM. 2021. Development and Validation of Machine Learning Models to Predict Admission From Emergency Department to Inpatient and Intensive Care Units. *Annals of Emergency Medicine*. 78(2):290–302. <https://doi.org/10.1016/j.annemergmed.2021.02.029>

Fernandes CMB, Tanabe P, Gilboy N, Johnson LA, McNair RS, Rosenau AM, Sawchuk P, Thompson DA, Travers DA, Bonalumi N, Suter RE. 2005. Five-Level Triage: A Report from the ACEP/ENA Five-Level Triage Task Force. *Journal of Emergency Nursing*. 31(1):39–50. <https://doi.org/10.1016/j.jen.2004.11.002>

Fernandes M, Mendes R, Vieira SM, Leite F, Palos C, Johnson A, Finkelstein S, Horng S, Celi LA. 2020a. Predicting Intensive Care Unit admission among patients presenting to the emergency department using machine learning and natural language processing. Olier I, editor. *PLoS ONE*. 15(3):e0229331. <https://doi.org/10.1371/journal.pone.0229331>

Fernandes M, Mendes R, Vieira SM, Leite F, Palos C, Johnson A, Finkelstein S, Horng S, Celi LA. 2020b. Risk of mortality and cardiopulmonary arrest in critical patients presenting to the emergency department using machine learning and natural language processing. Olier I, editor. *PLoS ONE*. 15(4):e0230876. <https://doi.org/10.1371/journal.pone.0230876>

Funakoshi H, Shiga T, Homma Y, Nakashima Y, Takahashi J, Kamura H, Ikusaka M. 2016. Validation of the modified Japanese Triage and Acuity Scale-based triage system emphasizing the physiologic variables or mechanism of injuries. *Int J Emerg Med*. 9(1):1. <https://doi.org/10.1186/s12245-015-0097-9>

Gaikwad SV, Chaugule A, Patil P. 2014. Text Mining Methods and Techniques. International Journal of Computer Applications. Volume 85(17).

Gerdan G. 2019. Knime ve Zemberek NLP ile Türkçe Döküman Sınıflandırma [Internet]. [accessed 2022 Feb 20]. <https://www.veribilimiokulu.com/knime-ve-zemberek-nlp-ile-turkce-dokuman-siniflandirma/>

Ghosh S, Bhatia S, Bhatia A. 2018. Quro: Facilitating User Symptom Check Using a Personalised Chatbot-Oriented Dialogue System. Stud Health Technol Inform. 252:51–56.

Gilboy N, Tanabe P, Travers DA. 2005. The Emergency Severity Index Version 4: Changes to ESI Level 1 and Pediatric Fever Criteria. Journal of Emergency Nursing. 31(4):357–362. <https://doi.org/10.1016/j.jen.2005.05.011>

Grafstein E, Bullard MJ, Warren D. 2008. Revision of the Canadian Emergency Department Information System (CEDIS) Presenting Complaint List Version 1.1. CJEM. 10(02):151–161. <https://doi.org/10.1017/S1481803500009878>

Grafstein E, Unger B, Bullard M, Innes G, the Canadian Emergency Department Information System (CEDIS) Working Group. 2003. Canadian Emergency Department Information System (CEDIS) Presenting Complaint List (Version 1.0). CJEM. 5(01):27–34. <https://doi.org/10.1017/S1481803500008071>

Grewal PDS. 2014. A Critical Conceptual Analysis of Definitions of Artificial Intelligence as Applicable to Computer Engineering. IOSR Journal of Computer Engineering. 16(2):09–13. <https://doi.org/10.9790/0661-16210913>

He Y, Yang L, Zhu X, Wu B, Zhang S, Qian C, Tian T. 2022. Mental Health Chatbot for Young Adults With Depressive Symptoms During the COVID-19 Pandemic: Single-Blind, Three-Arm Randomized Controlled Trial. *J Med Internet Res*. 24(11):e40719. <https://doi.org/10.2196/40719>

Heffernan DS, Thakkar RK, Monaghan SF, Ravindran R, Adams CA, Kozloff MS, Gregg SC, Connolly MD, Machan JT, Cioffi WG. 2010. Normal Presenting Vital Signs Are Unreliable in Geriatric Blunt Trauma Victims. *Journal of Trauma: Injury, Infection & Critical Care*. 69(4):813–820. <https://doi.org/10.1097/TA.0b013e3181f41af8>

Heinze DT, Morsch ML, Holbrook J. 2001. Mining free-text medical records. *Proc AMIA Symp.*:254–258.

Hirosawa T, Harada Y, Yokose M, Sakamoto T, Kawamura R, Shimizu T. 2023. Diagnostic Accuracy of Differential-Diagnosis Lists Generated by Generative Pretrained Transformer 3 Chatbot for Clinical Vignettes with Common Chief Complaints: A Pilot Study. *IJERPH*. 20(4):3378. <https://doi.org/10.3390/ijerph20043378>

Horng S, Sontag DA, Halpern Y, Jernite Y, Shapiro NI, Nathanson LA. 2017. Creating an automated trigger for sepsis clinical decision support at emergency department triage using machine learning. Groza T, editor. *PLOS ONE*. 12(4):e0174708. <https://doi.org/10.1371/journal.pone.0174708>

Iserson K V., Moskop JC. 2007. Triage in Medicine, Part I: Concept, History, and Types. *Annals of Emergency Medicine*. 49(3):275–281. <https://doi.org/10.1016/j.annemergmed.2006.05.019>

Joseph JW, Leventhal EL, Grossestreuer AV, Wong ML, Joseph LJ, Nathanson LA, Donnino MW, Elhadad N, Sanchez LD. 2020. Deep-learning approaches to identify critically ill patients at emergency department triage using limited information. *Journal of the American College of Emergency Physicians Open*. 1(5):773–781. <https://doi.org/10.1002/emp2.12218>

Kijpaisalratana N, Sanglertsinlapachai D, Techaratsami S, Musikatavorn K, Saoraya J. 2022. Machine learning algorithms for early sepsis detection in the emergency department: A retrospective study. *International Journal of Medical Informatics*. 160:104689. <https://doi.org/10.1016/j.ijmedinf.2022.104689>

Kim J, Chang H, Kim D, Jang D-H, Park I, Kim K. 2020. Machine learning for prediction of septic shock at initial triage in emergency department. *Journal of Critical Care*. 55:163–170. <https://doi.org/10.1016/j.jcrc.2019.09.024>

Kim Y, Kim J-H, Kim Y-M, Song S, Joo HJ. 2023. Predicting medical specialty from text based on a domain-specific pre-trained BERT. *International Journal of Medical Informatics*. 170:104956. <https://doi.org/10.1016/j.ijmedinf.2022.104956>

King MR. 2022. The Future of AI in Medicine: A Perspective from a Chatbot. *Ann Biomed Eng*. <https://doi.org/10.1007/s10439-022-03121-w>

Kittipimpanon K, Noyudom A, Panjatharakul P, Visudtibhan PJ. 2022. Use of and Satisfaction With Mobile Health Education During the COVID-19 Pandemic in Thailand: Cross-sectional Study. *JMIR Form Res*. <https://doi.org/10.2196/43639>

Klug M, Barash Y, Bechler S, Resheff YS, Tron T, Ironi A, Soffer S, Zimlichman E, Klang E. 2020. A Gradient Boosting Machine Learning Model for Predicting Early Mortality in the Emergency Department Triage: Devising a Nine-Point Triage Score. J GEN INTERN MED. 35(1):220–227. <https://doi.org/10.1007/s11606-019-05512-7>

KNIME A. KNIME Textprocessing [Internet].
<https://hub.knime.com/knime/extensions/org.knime.features.ext.textprocessing/latest>

Kwon H, Kim YJ, Jo YH, Lee Jae Hyuk, Lee Jin Hee, Kim J, Hwang JE, Jeong J, Choi YJ. 2019. The Korean Triage and Acuity Scale: associations with admission, disposition, mortality and length of stay in the emergency department. International Journal for Quality in Health Care. 31(6):449–455. <https://doi.org/10.1093/intqhc/mzy184>

Lee SH, Levin D, Finley PD, Heilig CM. 2019a. Chief complaint classification with recurrent neural networks. Journal of Biomedical Informatics. 93:103158. <https://doi.org/10.1016/j.jbi.2019.103158>

Levin S, Toerper M, Hamrock E, Hinson JS, Barnes S, Gardner H, Dugas A, Linton B, Kirsch T, Kelen G. 2018a. Machine-Learning-Based Electronic Triage More Accurately Differentiates Patients With Respect to Clinical Outcomes Compared With the Emergency Severity Index. Annals of Emergency Medicine. 71(5):565-574.e2. <https://doi.org/10.1016/j.annemergmed.2017.08.005>

Lockwood C, Conroy-Hiller T, Page T. 2004a. Vital signs. JBI Reports. 2(6):207–230. <https://doi.org/10.1111/j.1479-6988.2004.00012.x>

Mersinli Ü, Aksan M. 2012. Part of Speech Tagging of Turkish. *Studia Uralo-altaica*. 49:319–329.

Muischnek K, Müürisep K, IOS Press, editors. 2018. Human language technologies -- the Baltic perspective: proceedings of the eighth International Conference Baltic HLT 2018. Amsterdam, Netherlands: IOS Press.

Nadkarni PM, Ohno-Machado L, Chapman WW. 2011. Natural language processing: An introduction. *Journal of the American Medical Informatics Association*. 18(5):544–551. <https://doi.org/10.1136/amiajnl-2011-000464>

Nemec M, Koller MT, Nickel CH, Maile S, Winterhalder C, Karrer C, Laifer G, Bingisser R. 2010. Patients Presenting to the Emergency Department With Non-specific Complaints: The Basel Non-specific Complaints (BANC) Study. *Academic Emergency Medicine*. 17(3):284–292. <https://doi.org/10.1111/j.1553-2712.2009.00658.x>

O'Neill KA, Molczan K. 2003. Pediatric Triage: A 2-Tier, 5-Level System in the United States: Pediatric Emergency Care. 19(4):285–290. <https://doi.org/10.1097/01.pec.0000086245.54586.58>

Pardey TGM. 2006. The clinical practice of Emergency Department Triage: Application of the Australasian Triage Scale—An extended literature review. *Australasian Emergency Nursing Journal*. 9(4):155–162. <https://doi.org/10.1016/j.aenj.2006.09.003>

Parker CA, Liu N, Wu SX, Shen Y, Lam SSW, Ong MEH. 2019. Predicting hospital admission at the emergency department triage: A novel prediction model. *The American*

Journal of Emergency Medicine. 37(8):1498–1504.
<https://doi.org/10.1016/j.ajem.2018.10.060>

Patel FN, Soni NR. 2012. Text mining: A Brief survey. In: International Journal of Advanced Computer Research. Vol. 4. 6th ed. India.

Pollock DA, Adams DL, Bernardo LM, Bradley V, Brandt MD, Davis TE, Garrison HG, Iseke RM, Johnson S, Kaufmann CR, et al. 1998. Data elements for emergency department systems, release 1.0 (DEEDS): A summary report. Academic Emergency Medicine. 5(2):185–193. <https://doi.org/10.1111/j.1553-2712.1998.tb02607.x>

Qi Y. 2012. Random Forest for Bioinformatics. In: Zhang C, Ma Y, editors. Ensemble Machine Learning [Internet]. New York, NY: Springer New York; [accessed 2023 Jul 19]; p. 307–323. https://doi.org/10.1007/978-1-4419-9326-7_11

Rahaman MdS, Ahsan MMT, Anjum N, Rahman MdM, Rahman MN. 2023. The AI Race is on! Google's Bard and Openai's Chatgpt Head to Head: An Opinion Article. SSRN Journal [Internet]. [accessed 2023 Apr 1]. <https://doi.org/10.2139/ssrn.4351785>

Raita Y, Goto T, Faridi MK, Brown DFM, Camargo CA, Hasegawa K. 2019a. Emergency department triage prediction of clinical outcomes using machine learning models. Crit Care. 23(1):64. <https://doi.org/10.1186/s13054-019-2351-7>

Rupnik R, Kukar M, Krisper M. 2007. Integrating Data Mining and Decision Support through Data Mining Based Decision Support System. Journal of Computer Information Systems. 47(3):89–104.

Russell SJ, Norvig P, Davis E. 2010. Introduction: The history of Artificial Intelligence. In: Artificial intelligence: a modern approach. 3rd ed. Upper Saddle River: Prentice Hall; p. 17–18.

Schneider D. 1979. An ambulatory care classification system: design, development and evaluation. *Health services research*. 14(1):77.

Schneider D, Appleton L, McLemore T. 1979. A reason for visit classification for ambulatory care. 78(i:iv):1–63.

Seker SE. 2015. Metin Madenciliği (Text Mining). *YBS Ansiklopedi*.(September):30–32. <https://doi.org/10.13140/RG.2.1.3646.2565>

Sterling NW, Patzer RE, Di M, Schrager JD. 2019a. Prediction of emergency department patient disposition based on natural language processing of triage notes. *Int J Med Inform*. 129:184–188. <https://doi.org/10.1016/j.ijmedinf.2019.06.008>

Than M, Flaws D, Sanders S, Doust J, Glasziou P, Kline J, Aldous S, Troughton R, Reid C, Parsonage WA, et al. 2014. Development and validation of the Emergency Department Assessment of Chest pain Score and 2 h accelerated diagnostic protocol: Emergency Department Assessment of Chest pain Score. *Emerg Med Australas*. 26(1):34–44. <https://doi.org/10.1111/1742-6723.12164>

Thompson DA, Eitel D, Fernandes CMB, Pines JM, Amsterdam J, Davidson SJ. 2006a. Coded Chief Complaints-Automated Analysis of Free-text Complaints. *Academic Emergency Medicine*. 13(7):774–782. <https://doi.org/10.1197/j.aem.2006.02.013>

Tootooni MS, Pasupathy KS, Heaton HA, Clements CM, Sir MY. 2019a. CCMapper: An adaptive NLP-based free-text chief complaint mapping algorithm. *Computers in Biology and Medicine*. 113:103398. <https://doi.org/10.1016/j.combiomed.2019.103398>

Travers DA, Haas SW. 2003. Using nurses' natural language entries to build a concept-oriented terminology for patients' chief complaints in the emergency department. *Journal of biomedical informatics*. 36(4–5):260–270.

Travers DA, Haas SW. 2006. Unified Medical Language System Coverage of Emergency-medicine Chief Complaints. *Academic Emergency Medicine*. 13(12):1319–1323. <https://doi.org/10.1197/j.aem.2006.06.054>

Turing A. 2004. In: Copeland BJ, editor. *The essential Turing: seminal writings in computing, logic, philosophy, artificial intelligence, and artificial life, plus the secrets of Enigma*. Oxford : New York: Clarendon Press ; Oxford University Press; p. 6–15.

Twomey M, Wallis LA, Thompson M Lou, Myers JE. 2012. The South African triage scale (adult version) provides valid acuity ratings when used by doctors and enrolled nursing assistants. *African Journal of Emergency Medicine*. 2(1):3–12. <https://doi.org/10.1016/j.afjem.2011.08.014>

Tzelios C, Contreras C, Istenes B, Astupillo A, Lecca L, Ramos K, Ramos L, Roca K, Galea JT, Tovar M, et al. 2022. Using digital chatbots to close gaps in healthcare access during the COVID-19 pandemic. *Public Health Action*. 12(4):180–185. <https://doi.org/10.5588/pha.22.0046>

- Unger B, Afilalo M, Boivin JF, Bullard M, Grafstein E, Schull M, Lang E, Colacone A, Soucy N, Xue X, Segal E. 2010. Development of the Canadian Emergency Department Diagnosis Shortlist. CJEM. 12(04):311–319. <https://doi.org/10.1017/S1481803500012392>
- Van Veen M, Steyerberg EW, Ruige M, Van Meurs AHJ, Roukema J, Van Der Lei J, Moll HA. 2008. Manchester triage system in paediatric emergency care: Prospective observational study. Bmj. 337(7673):792–795. <https://doi.org/10.1136/bmj.a1501>
- Yılmaz H, Yumuşak, Semih. 2021. Açık Kaynak Doğal Dil İşleme Kütüphaneleri. İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi. 1. <https://doi.org/10.47769/izufbed.879217>
- Yun H, Choi J, Park JH. 2021. Prediction of Critical Care Outcome for Adult Patients Presenting to Emergency Department Using Initial Triage Information: An XGBoost Algorithm Analysis. JMIR Med Inform. 9(9):e30770. <https://doi.org/10.2196/30770>
- Zhang Yuhao, Zhang Yuhui, Qi P, Manning CD, Langlotz CP. 2021. Biomedical and clinical English model packages for the Stanza Python NLP library. Journal of the American Medical Informatics Association. 28(9):1892–1899. <https://doi.org/10.1093/jamia/ocab090>
- Zhou Z-H. 2003. Three perspectives of data mining. Artificial Intelligence. 143(1):139–146. [https://doi.org/10.1016/S0004-3702\(02\)00357-0](https://doi.org/10.1016/S0004-3702(02)00357-0)

7. ÖZGEÇMİŞ

Kişisel Bilgiler

Adı	Göksu	Uyruğu	T.C.
Soyadı	Bozdereli Berikol	Tel no	
Doğum tarihi		e-posta	

Eğitim Bilgileri

Mezun olduğu kurum		Mezuniyet yılı
Lise	İçel Anadolu Lisesi	2003
Lisans	Başkent Üniversitesi Tıp Fakültesi	2009
Lisans	Anadolu Üniversitesi İşletme Fakültesi İşletme	2010
Tıpta Uzmanlık	Mersin Üniversitesi Tıp Fakültesi Acil Tıp	2014
Yüksek Lisans	Gazi Üniversitesi Bilişim Enstitüsü Sağlık Bilişimi	2014
Doktora	Akdeniz Üniversitesi Sağlık Bilimleri Enstitüsü Tıp Bilişimi	2022

İş Deneyimi

Görevi	Kurum	Süre (yıl-yıl)
Pratisyen Dr.	Iğdır Tuzluca İlçesi Gaziler Köyü Sağlık Ocağı	2009-2009
Arş. Gör. Dr	Mersin Üniversitesi Tıp Fakültesi Acil Tıp	2010-2014

Uzman Dr.	Karaman Devlet Hastanesi	2014-2016
Uzman Dr.	Başkent Üniversitesi Tıp Fakültesi Acil Tıp A.D	2017-2018
Uzman Dr.	İstanbul Bakirkoy Dr Sadi Konuk Eğitim ve Araştırma Hastanesi Acil Tıp Kliniği	2018-

Yabancı Dilleri	Sınav türü	Puanı
İngilizce	YÖKDİL	92

Proje Deneyimi

Proje Adı	Destekleyen kurum	Süre (Yıl-Yıl)
Comparison of the biochemical and pathological efficacy of fluid resuscitation and L-arginine treatments in rats with traumatic brain injury and hemorrhagic shock model.	Mersin Üniversitesi	2013-2014
Fostering Research and Innovation in Emergency Medicine in Turkey Through Multidisciplinary Cooperation	U.S. Embbasy Ankara	2019-2020

Burslar-Ödüller:

Yayınlar ve Bildiriler:

1. Berikol, Göksu, Serdar Kula, and Oktay Yıldız. "Machine Learning Techniques in Diagnosis of Pulmonary Embolism Pulmoner Emboli Tanısında Makine Öğrenmesi Teknikleri." Journal of Clinical and Analytical Medicine 2015 1: 10.
2. Berikol, Göksu Bozdereli, Oktay Yıldız, and İ. Türkay Özcan. "Diagnosis of acute coronary syndrome with a support vector machine." Journal of medical systems 40.4 (2016): 1-8.
3. Berikol, G. B., İlhan, B., & Doğan, H. (2021). Satisfaction, Perspective, and Attitude Toward E-learning among Emergency Medicine Physicians. Medical Journal of Bakirkoy, 17(4).
4. Berikol, G., Berikol, G. B., & Dogan, H. (2021). Retrospective Analysis of Intracranial Hemorrhages in the COVID-19 Pandemic. Turkish Neurosurgery, 31(5).
5. İlhan, B., Berikol, G. B., & Dogan, H. (2021). Impact of COVID-19 Outbreak on Emergency Visits and Emergency Consultations: A Cross-Sectional Study. Cureus, 13(3).
6. İlhan, B., Bozdereli Berikol, G., Aydın, H., Arslan Erduhan, M., & Doğan, H. (2021). COVID-19 outbreak impact on emergency trauma visits and trauma surgery in a level 3 trauma center. Irish Journal of Medical Science (1971-), 1-6.
7. İlhan, B., Doğan, H., Berikol, G. B., Uçar, Y. G., & Sarbay, İ. (2021). An extremely rare complication of acute pancreatitis: Intraventricular thrombus. The American journal of emergency medicine, 45, 679-e5.

8. İlhan B, Berikol GB, Doğan H. The Authors' respond: The origin of intraventricular thrombus. Am J Emerg Med. 2021 Jul;45:591. doi: 10.1016/j.ajem.2020.12.034. Epub 2020 Dec 23. PMID: 33371975.
9. Bozdereli Berikol, G., Aydın, H., & Doğan, H. (2022). Early discharging patients with chest pain using EDACS-ADP and COMPASS-MI risk predictors. Heart and Vessels, 1-10.
10. Bozdereli Berikol G, Berikol G, Ayrik C, Kose A, Bozkurt Babus S, Tamer Gumus L, Bozdogan Arpacı R, Dag A, Ayan E, Gorur A. Antioxidant and Neuroprotective Effects of L-arginine Administration After Traumatic Brain Injury and Hemorrhagic Shock in Rats. Turk Neurosurg. 2022 Feb 2. doi: 10.5137/1019-5149.JTN.35263-21.2. Epub ahead of print. PMID: 35929035.
11. Aydın, H., Berikol, G. B., Kocak, M., & Doğan, H. The effect of variants and vaccines on prognosis in coronavirus disease 2019 patients: a retrospective observational study. Anatolian Clinic the Journal of Medical Sciences, 27(3), 293-301.
12. İlhan, B., Berikol, G. B., & Doğan, H. (2022). Impact of COVID-19 Outbreak on Pediatric Trauma Cases in a Tertiary Trauma Center. Medical Journal of Bakirkoy, 18(1).
13. Aydın, H., Bestemir, A., Berikol, G. B., & Doğan, H. (2022). Pandemi Hastanesinin Acil Servisine Başvuran Hastaların Analizi: Bir Retrospektif Türkiye Çalışması. Tıbbi Sosyal Hizmet Dergisi, (19), 76-85.
14. İlhan, B., Bozdereli Berikol, G., & Doğan, H. (2022). The predictive value of modified risk scores in patients with acute exacerbation of COPD: a retrospective cohort study. Internal and Emergency Medicine, 1-9.

7. ORAL AND POSTER PRESENTATIONS

1. The effect of hypocalcemia on poor outcomes in COVID-19 patients: A cross-sectional study. Buğra İlhan, Göksu Bozdereli Berikol, Halil Doğan. 7th Euroasian Congress on Emergency Medicine, 17th Turkish Congress on Emergency Medicine, Antalya, 25-28 November 2021
2. Performance of Chosen Score on the Discharge of COVID-19 Patients, **Göksu Bozdereli Berikol**, Hakan Aydın, Halil Doğan, 11th Asian Conference on Emergency Medicine 17-19 December 2021
3. Thyroid Cartilage Fracture after blunt neck trauma: A case report, **Göksu Bozdereli Berikol**, Attila Beştemir, Duygu Kara Bozkurt, Ökkeş Taha Küçükdağlı, Özgür Özdemir, Halil Doğan, 13th European Emergency Medicine Congress, 2019
4. Usability Evaluation Of Web-Based Triage Training For Emergency Service Staff **Göksu Bozdereli Berikol**, Neşe Zayım 11. Ulusal Tıp Bilişimi kongresi 2018
5. Zihinsel Engellilerde Eğitimin Başarıya Etkisi: Bir Veri Madenciliği **Göksu Bozdereli Berikol** , Uğur Bilge , Hilal Bozdereli, Gürkan Berikol 11. Ulusal Tıp Bilişimi kongresi 2018
6. Is Virtual Reality Effective on CPR Training: A Systematic Review **Göksu Bozdereli Berikol**, Gürkan Berikol 6th Eurasian Congress on Emergency Medicine 2018
7. Facet joint cyst: Case report Gürkan Berikol, **Göksu Bozdereli Berikol** European Association of Neurosurgical Societies Congress 2018

8. **Goksu Bozdereli Berikol**, Ugur Bilge, Hilal Bozdereli, Gurkan Berikol Zihinsel Engellilerde Eđitimin Bařarıya Etkisinin Veri Madenciliđı Yöntemleri ile Tahmini 2nd International Congress on Early Childhood Intervention 2018
9. Magnetic resonance imaging in spinal trauma: A case report **Goksu Bozdereli Berikol**, Gurkan Berikol, 12th European Congress of Emergency Medicine, 2018,
10. Imaging the examination signs: Case report **Göksu Bozdereli Berikol**, Gürkan Berikol, Southeast European Journal of Emergency and Disaster Medicine Vol. IV, Year 2018, Suppl
11. Acil Servis Çalışanları İçin Triyaj Eđitimi Web Sitesinin Kullanılabilirlik Deđerlendirilmesi " **Bozdereli Berikol G.**, Zayım N., .X. Tıp Biliřimi Kongresi, Antalya, Turkey, 13-14 Ekim 2017
12. Evaluation of Geriatric Patients Admitted with Falls to Emergency Department Betül Akbuđa Özel, **Göksu Bozdereli Berikol**, Elmas Burcu Mamak Ekinci 9th Asian Conference of Emergency Medicine, 2017
13. Isodense Intracranial Subdural Hematoma **Göksu Bozdereli Berikol**, Gürkan Berikol 9th Asian Conference of Emergency Medicine, 2017
14. Approach to The Prolonged Complaints in Emergency Department: 2 Cases **Göksu Bozdereli Berikol**, Gürkan Berikol 9th Asian Conference of Emergency Medicine, 2017

15. Interforaminal Stenosis: Interbody Cage as Better Selection in Lumbar Interbody Fusion, Gurkan Berikol Goksu Bozdereli Berikol Global Spine Congress, 2017
16. Bilgisayarlı Tomografinin normal olduđu subdural ampiyem olgusu, Goksu Bozdereli Berikol Gurkan Berikol 5 th Eurasian Congress on Emergency Medicine, 2016
17. A helpful method for emergency service: Predicting the ischemic cerebrovascular disease with data mining, Goksu Bozdereli Berikol , Gurkan Berikol 5 th Eurasian Congress on Emergency Medicine, 2016
18. Be careful! It may be emphysematous cystitis. Attila Bestemir, Goksu Berikol , Mehmet Serkan Yurdakul - Turkey
19. A different view to appendicitis with artificial intelligence, Goksu Bozdereli Berikol , Gurkan Berikol, Oktay Yildiz, Mehmet Serkan Yurdakul, Attila Bestemir 11 th European Congress of Emergency Medicine, 2016
20. Machine learning with acute coronary syndrome, Goksu Bozdereli Berikol , Gurkan Berikol, Oktay Yildiz, Ismail Turkay Ozcan 11 th European Congress of Emergency Medicine, 2016
21. Different kind of ileus: Internal hernia, 11 th European Congress of Emergency Medicine, Goksu Bozdereli Berikol , Gurkan Berikol, Mehmet Serkan Yurdakul, Attila Bestemir, Firat Kizilkaya 2016

22. Penetrating aortic ulceration:A predictable aort dissection, Goksu Bozdereli Berikol, Gurkan Berikol, Onur Saydam, Attila Bestemir, Mehmet Serkan Yurdakul, Ismail Ekinozu 11th European Congress of Emergency Medicine, 2016
23. Six month analysis of simple decompressions for ulnar entrapment, Gurkan Berikol Goksu Bozdereli Berikol 16th European Congress of Neurosurgery, 2016
24. Surgical removal of intracranial cyst hydatid in three month pregnant woman, Gurkan Berikol Mehmet Ali Karataş, Goksu Bozdereli Berikol, 16th European Congress of Neurosurgery, 2016
25. G. Berikol, G. Reşitoğlu, G.B. Berikol. İatrojenik lomber kifoz olgusu. Türk Nöroşirurji Dergisi, 2016, 26(Ek):351
26. G. Berikol, G. Berikol. To discharge or to follow-up 9th European Congress on Emergency Medicine, 10-14.10.2015, Torino, Italy (P958)
27. G. Berikol, G. Berikol, G. Resitoglu. A symptomatic sacral tarlov cyst: case report, 15th Interim Meeting of the World Federation of Neurosurgical Societies 8-12.09.2015, Rome, Italy (P1108)
28. G. Berikol, G. Berikol, Y. Kurucay, M.S. Yurdakul, T. Onge A rare diagnosis of upper abdomen: Splenic cyst hydatid MEMC-GREAT 2015 Joint Congress, 5-9.09.2015 Rome,Italy (W380)

29. Mehmet Serkan Yurdakul, Göksu Berikol , Tuğrul Önge, Nurhayat Başkaya, İsa Başpınar Acaba bu hasta kimin? 2. Intercontinental Emergency Medicine Congress, Antalya 16-19 Nisan 2015
30. Comparison of biochemical and pathological efficacy of fluid resuscitation and L-Arginine therapies in an experimentally formed traumatic brain injury and hemorrhagic shock model in rats. Göksu Bozdereli ,Cüneyt Ayırık,Ataman Köse,Seyran Bozkurt,Lülüfer Tamer,Rabia Bozdoğan Arpacı, <u>Ahmet Dağ</u> ,Gürkan Berikol,Erhan Ayan, <u>Hüseyin Narcı</u> (13.11.2014 -16.11.2014) , Yayın Yeri:4th Eurasian Congress On Emergency Medicine
31. Kolonoskopik polipektomi sonrası retroperitoneal kolon perforasyonu ve pnömomediastinum olgusu Seyran Bozkurt, Göksu Bozdereli ,Cüneyt Ayırık,Ataman Köse,Meltem Nass Duce,Enver Üçbilek (02.10.2013 -06.10.2013) , Yayın Yeri:9. Türkiye Acil Tıp Kongresi,
32. Alt gastrointestinal kanamanın nadir bir nedeni: Aorta-Çekal fistül. Cüneyt Ayırık, Göksu Bozdereli ,Seyran Bozkurt,Ataman Köse,Engin Kara,Meltem Nass Duce (03.10.2013 -06.10.2013) , Yayın Yeri:9. Türkiye Acil Tıp Kongresi
33. Karaaslan U., Ayırık C, Dağ A., Helvacı İ, Uyungül E, Demir F, Bozdereli G. , “Lökosit sayım, nötrofil oranı ve C reaktif protein konsantrasyonlarının cut-off düzeylerinde Apandisit tanısı koymadaki değerleri”, VII. Türkiye Acil Tıp Kongresi, Trabzon, 13-16 Ekim 2011

8. BOOKS/CHAPTERS

1. Berikol, G. B., & Berikol, G. (2020). Use of artificial intelligence in emergency medicine. In Artificial Intelligence in Precision Health (pp. 405-413). Academic Press.
2. Berikol, G. B., & Berikol, G. (2020). Predictive models in precision medicine. In Artificial Intelligence in Precision Health (pp. 177-188). Academic Press.
3. Berikol, G. B., Berikol, G., & Bozdereli, D. (2020). Artificial intelligence in neuro, head, and neck surgery. In Artificial Intelligence in Precision Health (pp. 393-404). Academic Press.
4. İntoksikasyonlar, Acil Algoritmaları, Editör Halil Doğan, 2021, EMA Tıp Kitabevi
5. Psikolojik Destek Uygulamaları, Afet Yönetimi ve Tıbbi Uygulamalar, Editör Serkan Emre Eroğlu, 2020, EMA Tıp Kitabevi

9. INTVITED LECTURES

1. AI in Telehealth, The Eurasian congress on emergency medicine, 1-4 December 2022, Antalya

2. Artificial Intelligence in Cardiovascular Emergencies, 2nd International Congress on emergency Medicine, November 2022, Antalya
3. Overcoming the tyranny of distance: improving healthcare equity and access by bringing the emergency doctor to the patient, A Turkish Perspective, International Congress on Emergency Medicine Melbourne 14-19 June 2022,
4. New Technologies in Emergency Care, 3rd Southeast European Emergency and Disaster Medicine Congress/5th Panhellenic Congress on Emergency Medicine, Thessaloniki, 2-5 June 2022
5. Machine learning in emergency medicine, 11th Asian Conference on Emergency Medicine, Virtual, 17-19 December 2021
6. Health Technologies and Artificial Intelligence in the Emergency Department in the Future, 1st International 6th National Emergency Nursing Congress, Virtual, 4-6 June 2021
7. Acil Tıpta Yapay Zeka (A.S. 4.0), 7th Euroasian Congress on Emergency Medicine, 17th Turkish Congress on Emergency Medicine, Antalya, 25-28 November 2021
8. Yapay Zekanın Acil Tıp Pratiginde Kullanımı, Uluslararası Katılımlı 16. Türkiye Acil Tıp Kongresi 20-22 Kasım 2020
9. EUSEM working together with the European Federation of Medical Informatics, European Emergency Medicine Congress, Prag, 2019

10. Virtual Reality: Are you ready for the future of medical education? 2nd Southeast European Congress of Emergency and Disaster medicine, Istanbul, 2019
11. Naloxone treatments in opioid overdose, 2nd Southeast European Congress of Emergency and Disaster medicine, 2019
12. Virtual Reality in Emergency Situations, First Southeastern European Emergency medicine Congress, Belgrade, 2018
13. Karın Ağrısına Yaklaşım 6. Acil Tıp Asistan Sempozyumu 2-5 Haziran 2011 Adrasan Antalya

8. EKLER

EK.1. Yataklı sağlık tesislerinde acil servis hizmetlerinin uygulama usul ve esasları hakkında tebliğde belirtilen Sağlık Bakanlığı Triyaj Renk kodları
(<https://www.resmigazete.gov.tr/eskiler/2022/09/20220913-5.htm>)

RENK	ALAN VE VAKA NİTELİĞİ	VAKANIN YÖNLENDİRİLDİĞİ BİRİM KRİTERLERİ	ÖRNEK DURUMLAR
Yeşil	Kategori 1: Ayaktan başvuran, genel durumu itibariyle stabil olan, akut semptomları sebebiyle 1 saatten fazla beklemesi hayati tehdit, morbidite veya komplikasyon oluşturabilecek basit sağlık sorunları bulunan hastalar.	Bu kategoride olan hastalar acil servis içerisinde yeşil alanda muayene edilmelidir.	* Genel durumu ve hayati bulguları stabil olan hastada her türlü basit belirti
			* Yüksek risk taşımayan ve hafif derecedeki her türlü ağrı * Aktif yakınması olmayan düşük riskli hastalık öyküsü
Sarı	Kategori 1: Hayati tehdit etme olasılığı, uzuv kaybı riski ve önemli morbidite oranı olan durumlar.	Bu kategoride değerlendirilen hastalar triajdan sorumlu hekimin bilgisi dahilinde doğrudan ilgili tanı/tedavi alanına alınmalıdır.	* Diastolik>110 mmHg, Sistolik>180 mmHg olan kan basıncı yüksekliği
			* Herhangi bir nedenle orta derecede kan kaybı
			* Yardımcı solunum kaslarının solunuma katılmadığı orta derecede solunum sıkıntısı
			* Nöbet geçirme öyküsü (uyanık)
			* Ateş yüksekliği olan onkoloji hastası veya steroid kullanan hasta
			* İnatçı kusma
			* Amnezi ile birlikte kafa travması olan ancak bilinci açık hasta

		* Kardiyak öykü ile uyumlu olmayan göğüs ağrısı
		* 65 yaş üstü karın ağrısı olan hasta
		* Şiddetli karın ağrısı olan hasta
		* Deformite, ciddi laserasyon ve ezilme yaralanması içeren ekstremiteler yaralanması
		* Suistimal riski veya şüphesi olan çocuk
		* Stresli ve kendine zarar verme riski olan hasta
	Kategori 2: Orta ve uzamış dönem belirtileri olan ve ciddiye potansiyeli taşıyan durumlar. (Solunum sayısı, nabız, kan basıncı, oksijen saturasyonu, vücut sıcaklığı anormal olan hastalar ile medikal tedavi ihtiyacı olan hastalar ve subjektif ağrı skoru maksimum skoru % 80'i olan hastalardır)	* Basit kanamalar
		* Göğüs ağrısı ve solunum sıkıntısı olmayan basit göğüs yaralanmaları
		* Solunum sıkıntısı olmayan yutma zorluğu
		* Bilinç kaybı olmayan minör kafa travmaları
		* Dehidratasyon belirtileri olmayan kusma ve ishaller
		* Normal görme fonksiyonu olan göz inflamasyonları veya gözde yabancı cisim
		* Minör ekstremiteler travması (ayak bileği burkulması, muhtemel basit fraktür, araştırma gerektiren komplike olmayan laserasyon) normal vital bulgular
		* Şiddetli olmayan karın ağrısı
		* Zarar verme riski olmayan davranış bozukluğu olan hastalar

Kırmızı	Kategori 1: Hayatı tehdit eden ve hızlı agresif yaklaşım ve acil olarak eş zamanlı değerlendirme ve tedavi gerektiren durumlar. Bu durumlarda hasta hiç bekletilmeden kırmızı alana alınır.	Kırmızı ana renk kodunda değerlendirilen hastalardan bilinci kapalı, hava yolu güvenliği, solunum ve dolaşımı olmayan hastalar derhal yeniden canlandırma (resusitasyon) odasına alınacaktır.	* Kardiyak arrest
			* Solunumsal arrest
			* Havayolu tıkanıklığı riski
			* Major çoklu travma
			* Solunum sayısı < 10/dakika
		Bilinci kapanabilecek, hava yolu güvensiz ve solunumu durabileceği ön görülen hastalar doğrudan kırmızı alana alınacaktır.	* Sistolik Kan Basıncı<80 (yetişkin) veya genel durumu bozuk çocuk veya infantlar
			* Devam eden veya uzamış nöbet
			* İlaç aşırı alımı olan hastanın yanıtsız veya hipoventilasyonda olması
			* Kardiyak ağrıya benzer göğüs ağrısı
			* Yardımcı solunum kaslarının solunuma katıldığı veya bakılabiliyor ise pulseoksimetri değerinin<90'nın altında olduğu ciddi nefes darlığı olan hastalar
	Kategori 2: Hayatı tehdit etme olasılığı yüksek olan ve 10 dakika içerisinde değerlendirilip tedavi edilmesi gerekli durumlar.		* Şiddetli stridor veya yutkunma güçlüğü ile beraber olan havayolu tıkanıklığı riski
			* Dolaşım bozukluğu
			-Nemli, soğuk deri, perfüzyon bozukluğu
			-Kalp hızı<50 veya >150 olması
			-Hemodinamik bulgularla beraber olan hipotansiyon

		* Akut hemiparazi/disfazi
		* Letarji ile birlikte ateş (her yaş)
		* İrrigasyon gerektiren asit/alkali ile göz teması
		* Major fraktür veya amputasyon gibi ciddi lokalize travma
		* Herhangi bir nedenle olan ciddi ağrı
		-Önemli sedatif veya diğer toksik maddelerin oral alımı
		* Davranışsal/Psikiyatrik
		-Şiddet içeren agresif davranışlar
		-Kendine veya diğerlerine zarar veren davranışlar

Ek.2: ESI Kural Algoritmaları

Kural 1#: Do You Need Resources? If «Resources»=0 Then «Esi»= 5 Ya da If (Lab= 0) And (Goruntuleme=0) And (Konsültasyon=0) And (Ilac=0 Or Saline Or Tetanus Profilaksisi Or Kapril) And (Malzeme=0 Or Malzeme=Alçı Altı Pamuk 10cm 2m Or Alçı Altı Pamuk 15cm 2m Or Elastik Bandaj 10cm) Then Esi 5; Else Esi<5
Kural 2# How Many Resources Do You Need? If «Resources»=1(Kaynak olmayanlardan ve en önemli girişimler dışındaki kaynaklardan biri olursa) Then «Esi»= 4 Ya da If (Lab ≥1) Or (Goruntuleme ≥1) Or (Konsültasyon ≥1) And (Ilac≠0 Or Naloxone Or D50 Or Dopamine Or Atropine Or Adenocard Or Adrenaline) Or (Malzeme ≠ 0 Or Malzeme=Alçı Altı Pamuk 10cm 2m Or Alçı Altı Pamuk 15cm 2m Or Elastik Bandaj 10cm Or Torakostomy Or Airway Or ETT Or Pace Or Io Access Or Kan Txf Seti) Then «Esi»= 4;
Kural 3# Life Saving Interventions If «Life Saving Interventions» ≥1 Then «Esi»= 1 If (Ilac=Naloxone Or Dopamine Or Atropine Or Adenocard Or Adrenaline Or Epinefrine) Or (Malzeme=Airway Or ...) Then «Esi»= 1 (Else Check Vital Signs)
Kural 4# Need Of Sources If («Lab Or Malzeme» ≥ 2) And («Lab Or Malzeme» ≠ Lifesaving Interventions) Then #Check Vital Signs If «Nabiz» ≥101 Or «Sat»≤91 Then Esi 2 Else Esi 3

Ek.3. Metin içerisindeki kelime ve kısaltmalara ait düzeltmeler

örnek kelimeler
ac ca >>>>>>>akciger kanseri
ab >>>>>>>antibiyotik
ac>>>>>>>akciger
age>>>>>>>akut gastroenterit
ahftadir>>>>haftadir
akc ca>>>>>>>akciger kanseri
kt>>>>>>>>kemoterapi
rt>>>>>>>>radoterapi/ rektal tuşe
ta>>>>>>>tansiyon
tarfimiza>>>>tarafimiza
kvah>>>>>>>kostovertebral aci hassasiyeti
bk>>>>>>>>bulanti kusma
kah>>>>>>>> koroner arter hastalığı
meme ca>>>> meme kanseri
mesane tm>>>>mesane kanseri
mesane ca>>>>mesane kanseri
agriis>>>>>>>agrisi
agriosi>>>>>>>agrisi
bulantsi>>>>>>>bulantisi
mide ca>>>>>>>mide kanseri
tbc>>>>>>>>tuberkuloz/taburcu
mgren/migrn>>>>>>>>migren
mr>>>>>>>>>manyetik rezonans görüntüleme
ms>>>>>>>>>multiple skleroz
neseף>>>>>>>>nefes
darliig>>>>>>>>darlığı
dm>>>>>>>>>diyabet
ht>>>>>>>>>hipertansiyon
lp>>>>>>>>>lomber ponksiyon
polde>>>>>>>>>poliklinikte
plk>>>>>>>>>poliklinik
pegף>>>>>>>>>gastrostomi
sik>>>>>>>>>sikayet
hf>>>>>>>>>hafta
hb/hgb>>>>>>>>>hemoglobin
trf>>>>>>>>>tarafı
usg>>>>>>>>>ultrason
aby>>>>>>>>>akut bobrek yetmezliği
kby>>>>>>>>>kronik bobrek yetmezliği
svo/svh>>>>>>>>>serebrovasküler olay
atipik ga>>>>>>>>>atipik göğüs ağrısı

Ek.4: Karar destek sistemi ve doğal dil işlemeye ait R ve Rshiny kodları örnekleri

RStudio

File Edit Code View Plots Session Build Debug Profile Tools Help

Go to file/function Addins

textdata

Filter

	sikayet	sonlanim	triyajrenk	esi	ontani
1	abisinin ?Rahatsızlığı sonrası epigastrik bölgesini tutanm için...	taburcu	sarı	4	HT
2	ablasyon anjio olan hastanın kasıkta ekimoz şişlik geldi	taburcu	sarı	4	NA
3	ablok çarpıntı göğüs ağrısı hipertansiyon ameliyat	taburcu	sarı	3	ARİTMİ
4	abse boşaltımı tarafımıza genel cerrahiden yönlendirilen has...	taburcu	yeşil	2	NA
5	abse drenaj gelen hasta dün başlayan boğaz ağrısı tarifliyor...	taburcu	sarı	2	USYE
6	akut böbrek yetmezliği nedeni daha önce yatışı olan birkaç ...	taburcu	sarı	3	NA
7	akut böbrek yetmezliği kronik böbrek yetmezliği geçen haf...	taburcu	sarı	3	NA
8	akut böbrek yetmezliği ön tanısı yönlendirilmiş haseki eah ...	taburcu	sarı	3	ABY
9	akut böbrek yetmezliği öntanısıyla yatış önko poliklinikten ...	yatış	sarı	2	ABY
10	akut böbrek yetmezliği sebebiyle dış merkezden yönlendiril...	taburcu	sarı	2	ABY
11	bacaklarda şişlik diltizem saneloc xarelto	taburcu	sarı	3	PAH
12	acde batma dünden beri	taburcu	sarı	4	NA
13	acde kitle sebebiyle takip edilen hasta hastanın sol kol her ik...	yatış	sarı	1	SÖLYET

Showing 1 to 14 of 54,867 entries, 5 total columns

R 4.0.3 · C:/Users/USER/Desktop/Rshiny/

```
> setwd("C:/Users/USER/Desktop/Rshiny")
> Sys.setlocale("LC_ALL","turkish")
[1] "LC_COLLATE=Turkish_Turkey.1254;LC_CTYPE=Turkish_Turkey.1254;LC_MONETARY=Turkish
254"
> library("readxl")
> textdata <- read_excel("table.xlsx")
> View(textdata)
```

```
setwd("C:/Users/USER/Desktop/Rshiny")
```

```
Sys.setlocale("LC_ALL","turkish")
```

```
library("readxl")
```

```
textdata <- read_excel("table.xlsx")
```

```
View(textdata)
```

#Doğal dil işleme paketlerinin yüklenmesi

```
install.packages("textmineR")
```

```
install.packages("SnowballC")
```

```
library("textmineR")
```

```
library("SnowballC")

library(readxl)

table <- read_excel("textdata.xlsx", sheet = 1)

# noktalama işaretlerinin kaldırılması

table[] <- lapply(table, function(x) gsub("[[:punct:]]", "",
x))
```

	id	sikayet	length
1	1016	alzheimer .(). Ve... ile..... hipertansiyon tanılı hastanın bir gü...	NA
2	35076	karın ağrısı kalp diyabet hipertansiyon batında hassasiyet	NA
3	41160	nrs acilden yönlendiririlen hasta sağ kol ve omuzda ağrısı me...	NA
4	27873	hemoroitedavisi için adet malak otu tohumu kullandığını bel...	NA

	id	sikayet	length
1	1016	alzheimer Ve ile hipertansiyon tanılı hastanın bir gündür b...	NA
2	35076	karın ağrısı kalp diyabet hipertansiyon batında hassasiyet	NA
3	41160	nrs acilden yönlendiririlen hasta sağ kol ve omuzda ağrısı me...	NA
4	27873	hemoroitedavisi için adet malak otu tohumu kullandığını bel...	NA
5	27449	hasta acil servise CPR eşliğinde getirildi hastanın genel duru...	NA

```
library(tm)

library(readxl)

data <- read_excel("table.xlsx", sheet = "Sheet1", col_names
= TRUE)

# Sütun adlarının Corpusa çevrilmesi
```

```

corpus <- Corpus(VectorSource(data$sikayet))

# Küçük harflere dönüştürme

corpus<-tm_map(corpus, content_transformer(tolower))

# Türkçe stopwordslerin belirlenmesi

stopwords <- c("ve", "ile", "veya", "Ve", "ya da", "de",
"da", "gibi", "için", "ile", "veya", "ama", "fakat", "ancak",
"eğer")

# Stopwords liste oluşturulması

stopwords <- c("ve", "ile", "veya", "ya da", "de", "da",
"gibi", "için", "ile", "veya", "ama", "fakat", "ancak",
"eğer")

# Corpustan stopwordslerin çıkarılması

corpus <- tm::tm_map(corpus, tm::removeWords, stopwords)

# Corpusu tekrar karakter vektöre dönüştürülmesi

new_text <- sapply(corpus, as.character)

# Yeni metni data frame'in metin sütunlarına atanması

data$sikayet <- new_text

# Excel dosyasına dataframein eklenmesi

write.xlsx(data,"table.xlsx", sheetName="Sheet1", append =
TRUE)

```

	id	sikayet	length	lab	goruntuleme	konsultasyon	sonlanim	tri
1	1016	alzheimer Ve ile hipertansiyon tanılı hastanın bir gündür b...	NA	0	0	1	yatış	
2	35076	karın ağrısı kalp diyabet hipertansiyon batında hassasiyet	NA	1	1	1	taburcu	
3	41160	nrs acilden yönlendirilen hasta sağ kol ve omuzda ağrısı me...	NA	1	1	1	taburcu	
4	27873	hemoroitedavisi için adet malak otu tohumu kullandığını bel...	NA	0	0	1	yatış	
5	27449	hasta acil servise CPR eşliğinde getirildi hastanın genel duru...	NA	0	0	0	yatış	
6	243	aitek sağ el sağ humerus sağ omuz hassasiyeti nazal dorsum ...	NA	0	1	1	yatış	
7	47161	ani hareketle artan bel ağrısı	NA	1	0	0	taburcu	
8	10275	bir haftadır bilinç bulanıklığı mevcut ara ara iye reçetesi veri...	NA	1	0	1	taburcu	
9	42476	öksürürken kan tükürme bilinen hipertansiyon tanılı hasta ac...	NA	1	1	1	yatış	

	id	sikayet	length	lab	goruntuleme	konsultasyon	sonlanim	tr
1	1016	alzheimer hipertansiyon tanılı hastanın bir gündür bulant...	NA	0	0	1	yatış	
2	35076	karn ağrısı kalp diyabet hipertansiyon batında hassasiyet	NA	1	1	1	taburcu	
3	41160	nrs acilden yönlendirilen hasta sağ kol omuzda ağrısı mevc...	NA	1	1	1	taburcu	
4	27873	hemoroitedavisi adet malak otu tohumu kullandığını belirte...	NA	0	0	1	yatış	
5	27449	hasta acil servise cpr eşliğinde getirildi hastanın genel duru...	NA	0	0	0	yatış	
6	243	aitek sağ el sağ humerus sağ omuz hassasiyeti nazal dorsum ...	NA	0	1	1	yatış	
7	47161	ani hareketle artan bel ağrısı	NA	1	0	0	taburcu	
8	10275	bir haftadır bilinç bulanıklığı mevcut ara ara iye reçetesi veri...	NA	1	0	1	taburcu	
9	42476	öksürürken kan tükürme bilinen hipertansiyon tanılı hasta ac...	NA	1	1	1	yatış	

```
#Makine öğrenmesi modellerinin oluşturulması
```

```
# İlgili paketlerin yüklenmesi
```

```
setwd("c:/users/USER/desktop/GoksuTez")
```

```
Sys.setlocale("LC_ALL","turkish")
```

```
install.package("readxl")
```

```
library("readxl")
```

```
install.package("dplyr")
```

```
library("dplyr")
```

```
#Sütunların faktöre dönüştürülmesi
```

```
d00 <- read_excel("table1.xlsx")
```

```
head(d00)
```

```
d00$triyajrenk <- as.factor(d00$triyajrenk)
```

```
d00$sonlanim <- as.factor(d00$sonlanim)
```

```
d00$ontani <- as.factor(d00$ontani)
```

```
str(d00)
```

```
d00$esi <- as.factor(d00$esi)
```

```
str(d00)
```

```

levels(d00$ontani)

summary(d00)

#Lookup dosyası oluşturularak Türkçe medikal kelimelerin ve
kısaltmaların düzeltilmesi

lookup <- read_xlsx("lookup.xlsx")

look <- setNames(lookup$V2, lookup$V1)

library(stringi)

Old <- lookup$V1 #df2[["vocabword"]]
New <- lookup$V2 #df2[["token"]]

s0 <- d00$sikayet

s1
stringi::stri_replace_all_regex(d00$sikayet, "\\s"%s+%Old%s+%
"s", New, vectorize_all = FALSE)

tail(s0, 30)

tail(s1, 30)

```

```

> tail(s0, 30)
[1] "dvt"           "grip"          "grip"
[4] "grip"          "grip"          "grip"
[7] "otit"          "otit"          "regl"
[10] "uste"          "usye"          "usye"
[13] "usye"          "usye"          "usye"
[16] "usye"          "usye"          "usye"
[19] "usye"          "usye"          "usye"
[22] "uyuz"          "uyuz"          "ara"
[25] "kronik böbrek yetmezliği" "pto"           "svt"
[28] "tit"           "ht"            "t"
> tail(s1, 30)
[1] "dvt"           "grip"          "grip"
[4] "grip"          "grip"          "grip"
[7] "otit"          "otit"          "regl"
[10] "uste"          "usye"          "usye"
[13] "usye"          "usye"          "usye"
[16] "usye"          "usye"          "usye"
[19] "usye"          "usye"          "usye"
[22] "uyuz"          "uyuz"          "ara"
[25] "kronik böbrek yetmezliği" "pto"           "svt"
[28] "tit"           "ht"            "t"
>

```

```
data <- d00
```

```

#ngram ve gplot oluşturma

library("tm")

library("SnowballC") # for stemming

library("wordcloud")

library("RColorBrewer")

text33 <- data$sikayet[1:54867]

library(RWeka)

library(ggplot2)

#ngramFunc <- function(text33, n) {

n=2

df <- data.frame(text =
  sapply(VCorpus(VectorSource(text33)), as.character),
  stringsAsFactors=F)

ngtok <- NGramTokenizer(df, Weka_control(min=n, max=n))

nGrams <- data.frame(table(ngtok))

nGrams <- nGrams[order(nGrams$Freq, decreasing=T),]

colnames(nGrams) <- c("Word", "Frequency")

nGrams_s <- nGrams[1:10,]

d00 <- cbind(d00,nGrams_s)

# Kolon isimlerinden yeni dataframe oluşturma

word_data <- as.data.frame(matrix(nrow = nrow(d00), ncol =
  nrow(nGrams_s)))

colnames(word_data) <- nGrams_s$Word

# Loop through each word and check if it exists in the sikayet
column

for(i in 1:nrow(nGrams_s)){

```

```

    word_data[,i]      <-      ifelse(grepl(nGrams_s$Word[i],
d00$sikayet), 1, 0)

}

# Excel dökümanına kelime kolonlarının eklenmesi

d00 <- cbind(d00, word_data)


# CSV dosyasının oluşturulması

write.csv(d00, "mat.csv", row.names = FALSE)

#Wordcloud ve ggplot yazdırılması

dev.new()

wordcloud(words      =      nGrams$Word,      freq      =      nGrams$Freq,
colors=brewer.pal(8, "Dark2"),

##rot.per=.10, min.freq=100,  scale=c(2, .1))

max.words=100, random.order=FALSE, rot.per=0)

dev.new()

ggplot (nGrams_s, aes (x = reorder (Word, Frequency), y =
Frequency)) +

    geom_bar(stat="identity",fill="green")  +  theme(text =
element_text(size=10)) +

    geom_text (aes(y = Frequency, label = Frequency), vjust
= 0.01, size=2.5) +

    coord_flip() +

    labs(x = "Word", y = "Frequency", title = "nGrams
Frequency")

table$triyajrenk <- as.factor(table$triyajrenk)

table$sonlanim <- as.factor(table$sonlanim)

table$ontani <- as.factor(table$ontani)

str(table)

```

```

table$esi <- as.factor(table$esi)

str(table)

levels(table$ontani)

summary(table)

```

```

> str(table)
Classes 'tbl_df', 'tbl' and 'data.frame':    54867 obs. of  14 variables:
 $ id      : chr  "1016" "35076" "41160" "27873" ...
 $ sikayet : chr  "alzheimer ve ile hipertansiyon tanılı hastanın bir gün
dür bulantı kusma günde defa ve kabızlık şikayetleri v"| __truncated__ "karın ağ
rısı kalp diyabet hipertansiyon batında hassasiyet" "nrs acilden yönlendiririlen
hasta sağ kol ve omuzda ağrısı mevcut" "hemoroitedavisi için adet malak otu tohu
mu kullandığını belirten hasta dun beş adet kullanmış  ağız kuruluğu ti"| __trun
cated__ ...
 $ length  : logi  NA NA NA NA NA NA ...
 $ lab      : chr  "0" "1" "1" "0" ...
 $ görüntuleme : chr  "0" "1" "1" "0" ...
 $ konsultasyon: chr  "1" "1" "1" "1" ...
 $ sonlanim  : Factor w/ 2 levels "taburcu","yatış": 2 1 1 2 2 2 1 1 2 1 ...
 $ triyajrenk : Factor w/ 3 levels "kırmızı","sarı",...: 1 2 2 1 1 2 2 2 2 ...
 $ nabız     : chr  "76" "106" "132" "82" ...
 $ saturasyon : chr  "85" "83" "94" "99" ...
 $ ilac      : chr  "0" "1" "0" "0" ...
 $ malzeme   : chr  "0" "1" "0" "0" ...
 $ esi       : Factor w/ 5 levels "1","2","3","4",...: 2 2 2 3 5 3 2 3 3 3 ...
 $ ontani    : Factor w/ 110 levels "ABY","AGE","AKUTBATIN",...: 27 3 12 52 11
97 61 14 44 5 ...

```

```

> summary(table)
      id      sikayet      length      lab
Length:54867 Length:54867 Mode:logical Length:54867
Class :character Class :character NA's:54867 Class :character
Mode :character Mode :character Mode :character

      görüntuleme      konsültasyon      sonlanım      triyajrenk
Length:54867 Length:54867 taburcu:51389 kırmızı: 5301
Class :character Class :character yatış : 3478 sarı :41939
Mode :character Mode :character yeşil : 7627

      nabız      saturasyon      ilaç      malzeme
Length:54867 Length:54867 Length:54867 Length:54867
Class :character Class :character Class :character Class :character
Mode :character Mode :character Mode :character Mode :character

esi      ontani
1: 28 NA : 7875
2:12738 AKUTBATIN: 7681
3:27528 USYE : 5653
4: 8235 AGE : 3352
5: 6338 AMİ : 3185
      SAK : 2996
      (Other) :24125

```

```

# ilgili kütüphanelerin yüklenmesi

library(xgboost)

library(pROC)

library(readxl)

library(caret)

#verisetinin dosya dan okunması

data = read_excel("matesi.xlsx")

#eğitim ve test setlerinin oluşturulması

set.seed(123)

```

```

splitIndex <- sample(1:nrow(data), 0.7*nrow(data))

train <- data[splitIndex,]

test <- data[-splitIndex,]

#Eğitim seti sütunlarının faktör olarak etiketlenmesi

train$sesi <- as.factor(train$sesi)

train$sesi <- as.integer(train$sesi) - 1

test$sesi <- as.integer(test$sesi) - 1

#XBOOST

#Eğitim ve test verisetlerinin oluşturulması ve performans analizi

model = xgboost(data = as.matrix(train[,1:200]), label = train$sesi,
nrounds = 10, objective = "multi:softmax", num_class = 3, nthread = 2,
eval_metric = "merror", verbose = TRUE)

#test setinde tahminlerin oluşturulması

predictions = predict(model, as.matrix(test[,1:200]))

performance = multiclass.roc(test$sesi, predictions)

#AUC hesaplama

library(pROC)

auc = auc(performance)

print(auc)

predictions <- factor(predictions, levels = levels(test$sesi))

# check the class of predictions

class(predictions)

# check the class of test$sesi

class(test$sesi)

predictions <- as.factor(predictions)

```

```

# ESI'nin faktör olarak belirlenmesi

test$sesi <- as.factor(test$sesi)

levels(predictions) == levels(test$sesi)

levels(predictions) <- levels(test$sesi)

confusion_matrix <- confusionMatrix(predictions, test$sesi)

library(caret)

# Confusion Matrixin hesaplanması

confusion_matrix <- confusionMatrix(predictions, test$sesi)

# Confusion Matrixin yazdırılması

print(confusion_matrix)

# Accuracy hesaplanması

accuracy <- sum(diag(confusion_matrix$table)) /
sum(confusion_matrix$table)

print(paste("Accuracy:", accuracy))

# Precision hesaplanması

precision <- confusion_matrix$byClass[1] /
(colSums(confusion_matrix$table))

print(paste("Precision:", precision))

# Recall hesaplanması

recall <- confusion_matrix$byClass[1] /
(rowSums(confusion_matrix$table))

print(paste("Recall:", recall))

# F1 skorunun hesaplanması

f1_score <- 2 * ((precision * recall) / (precision + recall))

print(paste("F1-score:", f1_score))

```

#RANDOMFOREST

```
#eğitim ve test verisetinin oluşturulması, ve performans analizi

Library(RandomForest)

matesi <- read_excel("matesi.xlsx")

# Eğitim ve test setinin oluşturulması

set.seed(123)

splitIndex <- createDataPartition(matesi $esi, p = .7, list = FALSE,
times = 1)

matesi _train <- matesi[splitIndex, ]

matesi _test <- matesi[-splitIndex, ]

colnames(matesi_train)

colnames(matesi_test)

colnames(matesi_train) <- gsub(" ", "_", colnames(matesi_train))

colnames(matesi_test) <- gsub(" ", "_", colnames(matesi_test))

# Random forest modelinin tanımlanması

model <- randomForest(es1 ~ ., data = matesi_train, ntree = 500, type =
"classification")

levels(matesi_test$esi) <-
levels(matesi_train$esi)[match(levels(matesi_test$esi),
levels(matesi_train$esi))]

predictions <- predict(model, newdata = matesi_test)

predictions <- factor(predictions, levels = levels(matesi2_train$esi))

matesi_test$esi <- as.factor(matesi_test$esi)

matesi_train$esi <- as.factor(matesi_train$esi)

confusion_matrix <- confusionMatrix(predictions, matesi2_test$esi)

rint(confusion_matrix)
```

#YAPAY SİNİR AĞLARI

#İlgili kütüphanelerin yüklenmesi

```
library(caret)
```

```
library(keras)
```

```
library(readxl)
```

```
library(tensorflow)
```

```
library(magrittr)
```

```
matttriyajrenk2 <- read_excel("matttriyajrenk2.xlsx")
```

```
set.seed(123)
```

```
splitIndex <- createDataPartition(matttriyajrenk2$triyajrenk, p = .7,  
list = FALSE, times = 1)
```

```
matttriyajrenk2_train <- matttriyajrenk2[splitIndex, ]
```

```
matttriyajrenk2_test <- matttriyajrenk2[-splitIndex, ]
```

```
matttriyajrenk2_train$triyajrenk <-  
as.factor(matttriyajrenk2_train$triyajrenk)
```

```
matttriyajrenk2_test$triyajrenk <-  
as.factor(matttriyajrenk2_test$triyajrenk)
```

```
# Get the number of input features
```

```
input_shape <- ncol(matttriyajrenk2_train[, -201])
```

```
model <- keras_model_sequential() %>%
```

```

    layer_dense(units = 200, activation = "relu", input_shape =
c(input_shape)) %>%

    layer_dense(units = 3, activation = "softmax")

model %>% compile(

    optimizer = "adam",

    loss = "categorical_crossentropy",

    metrics = c("accuracy")
)

model %>% fit(

    as.matrix(matttriyajrenk2_train[, -201]),
    to_categorical(matttriyajrenk2_train$triyajrenk),

    epochs = 10, batch_size = 32, validation_split = 0.2
)

# Make predictions on the test set

predictions <- model %>% predict(as.matrix(matttriyajrenk2_test[, -201]))
%>% k_argmax()

# Convert the predictions to factor

predictions <- as.numeric(predictions)

predictions <- as.factor(predictions)

```

```

# Evaluation on the test set

model %>% evaluate(as.matrix(mattriyajrenk2_test[, -201]),
  to_categorical(mattriyajrenk2_test$triyajrenk))

levels(predictions) <- levels(mattriyajrenk2_test$triyajrenk)

# Create confusion matrix

cm <- confusionMatrix(predictions, mattriyajrenk2_test$triyajrenk)

# Print confusion matrix

print(cm)

# Calculate Sensitivity, Specificity, PPV, NPV, and AUROC

sensitivity <- cm$byClass["Sensitivity"]

specificity <- cm$byClass["Specificity"]

PPV <- cm$byClass["Pos Pred Value"]

NPV <- cm$byClass["Neg Pred Value"]

library(pROC)

roc_obj <- multiclass.roc(mattriyajrenk2_test$triyajrenk,
  as.numeric(predictions))

AUROC <- roc_obj$auc

# Print Sensitivity, Specificity, PPV, NPV, and AUROC

cat("Sensitivity:", sensitivity, "\n")

cat("Specificity:", specificity, "\n")

cat("PPV:", PPV, "\n")

cat("NPV:", NPV, "\n")

```

```

cat("AUROC:", AUROC, "\n")

print(cm)

library(shiny)

library(readxl)

library(keras)

library(textTinyR)

library(caret)

library(tm)

install.packages("RWeka")

library(RWeka)

matesi <- read_excel("matesi.xlsx", col_names = TRUE)

print(names(matesi))

names(matesi) <- gsub("\\\\...*", "", names(matesi))

print(names(matesi))


set.seed(123)

smp_size <- floor(0.7 * nrow(matesi))

train_ind <- sample(seq_len(nrow(matesi)), size = smp_size)

train <- matesi[train_ind, ]

test <- matesi[-train_ind, ]

train$sesi <- as.numeric(train$sesi)

test$sesi <- as.numeric(test$sesi)

train_y <- to_categorical(train$sesi)

test_y <- to_categorical(test$sesi)

model <- keras_model_sequential()

model %>%

  layer_dense(units = 256, activation = 'relu', input_shape =
ncol(train)) %>%

```

```

    layer_dense(units = 128, activation = 'relu') %>%
    layer_dense(units = 5, activation = 'softmax')
model %>% compile(
  loss = 'categorical_crossentropy',
  optimizer = optimizer_rmsprop(),
  metrics = c('accuracy')
)
history <- model %>% fit(
  as.matrix(train),
  train_y,
  epochs = 30,
  batch_size = 128,
  validation_data = list(as.matrix(test), test_y)
)
train_pred_probs <- model %>% predict(as.matrix(train))
train_pred <- k_argmax(train_pred_probs) %>% as.integer()
test_pred_probs <- model %>% predict(as.matrix(test))
test_pred <- k_argmax(test_pred_probs) %>% as.integer()
train_res <- confusionMatrix(as.factor(train_pred),
  as.factor(train$sesi))
test_res <- confusionMatrix(as.factor(test_pred), as.factor(test$sesi))
save_model_hdf5(model, "model.h5")
# Bigramları oluşturma fonksiyonu
create_bigrams <- function(text) {
  # Texti küçük harfe çevir
  text <- tolower(text)
  # Özel karakterleri ve sayıları kaldır
  text <- gsub("[^[:alpha:][:space:]]*", "", text)
  # Tekrar eden boşlukları kaldır

```

```

text <- gsub("\\s+", " ", text)

# Bigramları oluştur

words <- unlist(strsplit(text, "\\s"))

bigrams <- paste(head(words, -1), tail(words, -1))

return(bigrams)
}

# NLP fonksiyonu

nlp_function <- function(complaint, colnames){
  ngram_vector <- rep(0, length(colnames))

  stopwords <- c("ve", "ile", "veya", "ya da", "de", "da", "gibi",
    "için", "ile", "veya", "ama", "fakat", "ancak", "eğer")

  complaint <- removeWords(complaint, stopwords)

  bigrams <- create_bigrams(complaint) # Burada bigramları oluşturun

  for(i in seq_along(colnames)){

    if(colnames[i] %in% bigrams){

      ngram_vector[i] <- 1

    } else {

      ngram_vector[i] <- 0

    }

  }

  return(list(ngram_vector = ngram_vector, bigrams = bigrams))
}

# Shiny uygulaması için UI tanımlama

ui <- fluidPage(

  titlePanel("ESI Prediction"),

  sidebarLayout(

    sidebarPanel(

      textInput("complaint", "Enter the complaint:"),

```

```

        actionButton("predict", "Predict")
    ),
    mainPanel(
        textOutput("prediction"),
        verbatimTextOutput("bigrams"),
        textOutput("train_acc"),
        textOutput("test_acc"),
        textOutput("train_sensitivity"),
        textOutput("train_specificity"),
        textOutput("train_ppv"),
        textOutput("train_npv"),
        textOutput("test_sensitivity"),
        textOutput("test_specificity"),
        textOutput("test_ppv"),
        textOutput("test_npv"),
        plotOutput("roc_curve")
    )
)
)

server <- function(input, output) {
  observeEvent(input$predict, {
    complaint <- input$complaint
    colnames <- names(matesi)
    nlp_results <- nlp_function(complaint, colnames)
    complaint_vector <- nlp_results$ngram_vector
    complaint_vector <- array_reshape(complaint_vector, c(1,
length(complaint_vector)))

    model <- load_model_hdf5("model.h5")
  })
}

```

```

prediction <- model %>% predict(complaint_vector)
predicted_class <- which.max(prediction)

bigrams <- nlp_results$bigrams
output$prediction <- renderText({
  paste("Predicted ESI: ", predicted_class)
})

output$bigrams <- renderPrint({
  print(bigrams)
})

output$train_acc <- renderText({
  paste("Train accuracy: ", round(train_res$overall['Accuracy'],
2))
})

output$test_acc <- renderText({
  paste("Test accuracy: ", round(test_res$overall['Accuracy'], 2))
})

output$train_sensitivity <- renderText({
  paste("Train Sensitivity: ",
round(train_res$byClass["Sensitivity"], 2))
})

output$train_specificity <- renderText({
  paste("Train Specificity: ",
round(train_res$byClass["Specificity"], 2))
})

output$train_ppv <- renderText({
  paste("Train Positive Predictive Value: ",
round(train_res$byClass["Pos Pred Value"], 2))
})

output$train_npv <- renderText({

```

```

    paste("Train Negative Predictive Value: ",
round(train_res$byClass["Neg Pred Value"], 2))

  })

  output$test_sensitivity <- renderText({

    paste("Test Sensitivity: ",
round(test_res$byClass["Sensitivity"], 2))

  })

  output$test_specificity <- renderText({

    paste("Test Specificity: ",
round(test_res$byClass["Specificity"], 2))

  })

  output$test_ppv <- renderText({

    paste("Test Positive Predictive Value: ",
round(test_res$byClass["Pos Pred Value"], 2))

  })

  output$test_npv <- renderText({

    paste("Test Negative Predictive Value: ",
round(test_res$byClass["Neg Pred Value"], 2))

  })

  output$roc_curve <- renderPlot({

    if (length(levels(factor(train$esi))) == 2) {

      roc_obj <- roc(response = factor(train$esi), predictor =
as.numeric(train_pred))

      plot(roc_obj, main="ROC Curve", xlab="1 - Specificity",
ylab="Sensitivity")

    }

  })

  })

}

# Uygulamayı çalıştır

shinyApp(ui = ui, server = server)

```

Ek.5. Öntanılara ait sayı ve yüzdesel dağılım

Öntani	n	%
Akut böbrek yetmezliği	563	1,0
Akut batın	7678	14,0
Allerji	588	1,1
Akut koroner sendrom	3185	5,8
Anal fissur	24	0,0
Anemi	266	0,5
Anorektal abse	12	0,0
Aort anevrizma rupturu	12	0,0
Aort disseksiyonu	6	0,0
Apandisit	3	0,0
Aritmi	819	1,5
Arrest	5	0,0
Artrit	493	0,9
Astım atak	128	0,2
Akut solunum yolu enfeksiyonu	1865	3,4
Bells paralizi	111	0,2
Crohn	1	0,0
Deliryum	8	0,0
Dermatit	275	0,5
Dismenore	119	0,2
Diyare	3352	6,1
Diyabetik ketoasidoz	167	0,3
Delici kesici alet yaralanması	1	0,0
Dorsalji	182	0,3
Ektopik gebelik	7	0,0
Elektrolit bozuklukları	106	0,2
Emboli	62	0,1
Enfeksiyon	404	0,7
Epilepsi	77	0,1
Epistaksis	262	0,5
Farenkste yabancı cisim	2	0,0
Fasial paralizi	8	0,0
Fraktür, ekstremit	34	0,1
Gebe	290	0,5
Gebe kolestaz	1	0,0
Gastrointestinal hemoraji	350	0,6
Glob vezikale	39	0,1
Glokom	139	0,3
Gözde yabancı cisim	4	0,0
Hematolojik aciller	79	0,1
Hematüri	190	0,3
Hemoptizi	78	0,1

Hemoroid	169	0,3
Herni	54	0,1
Herpes	8	0,0
Hiperglisemi	3	0,0
Hipoglisemi	26	0,0
Hipotansiyon	38	0,1
Hipertansiyon	1275	2,3
Ileus	282	0,5
Intoksikasyonlar	15	0,0
İdrar yolu enfeksiyonu	2636	4,8
Kanama bozuklukları	28	0,1
Karaciğer sirozu	27	0,0
Koah atak	64	0,1
Kolesistit	129	0,2
Konjuktivit	403	0,7
Kulakta yabancı cisim	6	0,0
Kalp yetmezliği, akut	154	0,3
Lumbalji	690	1,3
Mastit	8	0,0
Menenjit	2	0,0
Ms atak	5	0,0
N/A	7875	14,4
Nefrolitiazis	23	0,0
Nekrotizan fasciit	1	0,0
Nöropatik ağrı	18	0,0
Onkolojik aciller	168	0,3
Otitis media/eksterna	493	0,9
Periferik arter hastalığı	267	0,5
Pankreatit	88	0,2
Penil fraktür	1	0,0
Pelvik inflamatuvar hastalık	60	0,1
Pilonidal abse	1	0,0
Pnömotoraks	25	0,0
Preeklampsi	6	0,0
Psikiyatrik aciller	119	0,2
Pulmoner tromboemboli	1033	1,9
Pyelonefrit	4	0,0
Renal infarkt	1	0,0
Renal kolik	1489	2,7
Subaraknoid kanama	2996	5,5
Selulit	312	0,6
Senkop	427	0,8
Sepsis	30	0,1
Solunum yetmezliği	5	0,0

Spinal yaralanma	6	0,0
Spinal noropati	118	0,2
Subkonjunktival hemoraji	45	0,1
Serebrovasküler hastalık, iskemik	777	1,4
Tetanoz	1	0,0
Tinnitus	20	0,0
Tiroid	11	0,0
Torsiyon	63	0,1
Travma	89	0,2
Tromboz/abse	48	0,1
Ürtiker	1	0,0
Üsye	5654	10,3
Uyuz	20	0,0
Vajinal kanama	314	0,6
Vajinit	11	0,0
Varikosel	1	0,0
Vertigo	1840	3,4
Yanık	2	0,0
Yabancı cisim	3	0,0
Yumuşak doku bozukluğu	887	1,6
Yumuşak doku travması	88	0,2
Zona	81	0,1