

Makine Öğrenme Tabanlı Hastane Triyaj Karar Destek Sistemi Uygulamasının Geliştirilmesi

Erhan TURAN¹

¹ Bilgisayar Mühendisliği, Mühendislik Fakültesi, Ardahan Üniversitesi, Ardahan, Türkiye

*¹ erhanturan@ardahan.edu.tr

(Geliş/Received: 10/09/2025;

Kabul/Accepted: 22/07/2026)

Öz: Bu çalışma ile hastanelerde yoğunluğun en fazla olduğu birim olan Acil bölümü için makine öğrenme tabanlı bir karar destek sistemi önerilmiştir. Yoğunluk, iş yükü, stres ve insan kaynaklı etkilerden dolayı çalışma alanının baskılandığı Acil birimi için hata payı azaltılarak gelen hastanın en doğru şekilde tıbbi destek alacağı birime yönlendirilme işlemleri yapılmaktadır. Acil birimlerinde gelen hastanın yeşil, sarı ve kırmızı alan olarak adlandırılan alanlara yönlendirilir. Hastaların doğru ve hızlı bir şekilde yönlendirilmesi bu alanlardaki yoğunluğun en verimli şekilde kullanılmasını ve hastaların tıbbi müdahale önceliklerine göre en doğru şekilde destek almasını sağlamaktadır. Bu çalışmada Kore’de bir bölgesel ve yerel hastanelerin acil bölümlerinden elde edilen açık kaynak veri seti kullanılmıştır. karar ağacı, Gaussian naif bayes, k-en yakın komşu, lightgbm, rasgele orman ve destek vektör makinesi kullanılarak sınıflandırma modelleri eğitilmiştir. Bu sınıflandırma modelleri ve eğitim setindeki verilerin girişinin yapıldığı ve hastanelerdeki acil birimlerinin kullanımına yönelik grafiksel arayüz Java swing kütüphanesi kullanılarak geliştirilmiştir. Sınıf modelleri ise Python ortamında derlenmiştir. Java ve Python komut satırı üzerinden haberleştirilerek uygulama bütün halinde çalıştırılarak gerçek ortam testlerine uygun hale getirilmiştir. Hastaların yeşil (under triage), sarı (normal triage) ve yeşil (over triage) alanlara doğru olarak yönlendirilmesinde geliştirilen makine öğrenme tabanlı karar destek sisteminde rasgele orman ağacı ve LGBM %96.1’luk test doğruluğuna ulaşmıştır.

Anahtar kelimeler: Triyaj, karar destek sistemi, makine öğrenmesi, grafiksel arayüz

Development of Machine Learning Based Hospital Triage Decision Support System Application

Abstract: This study proposes a machine learning-based decision support system for the emergency department (ED), which is typically the most congested unit in hospitals. In EDs, where the workspace is highly constrained by congestion, workload, stress, and human factors, the margin of error is significantly reduced. Therefore, it is crucial to ensure that incoming patients are directed to the most appropriate unit for medical support. In emergency departments, incoming patients are directed to areas designated as Green, Yellow, and Red Zones. Accurate and rapid patient orientation is essential for the most efficient use of capacity in these congested areas and ensures that patients receive the most appropriate support according to their medical priorities. This study utilizes an open-source dataset obtained from the emergency departments of regional and local hospitals in Korea. Classification models were trained using Decision Trees, Gaussian Naive Bayes, K-Nearest Neighbors, LightGBM, Random Forests, and Support Vector Machines. These classification models, along with the training data, were developed with the Java Swing library to create a graphical interface for use in hospital emergency departments. The classification models themselves were compiled in Python. The entire application was run via the Java and Python command line, making it suitable for real-world testing. The Random Forest and LGBM models achieved %96.1 test accuracy in the machine learning-based decision support system developed to correctly direct patients to the Green (under triage), Yellow (normal triage), and Red (over triage) areas.

Keywords: Triage, decision support system, machine learning, graphical interface

1. Giriş

Hastanelerdeki Acil bölümü sağlık hizmetlerinin kesintisiz verildiği en yoğun alandır. Bu nedenle buradaki hasta, idari çalışan ve sağlık çalışanı arasındaki koordinasyonunda oluşan aksaklıklar verimsiz bir çalışma süreci yaşanmasına neden olmaktadır. Bu nedenle Acil bölümüne başvuran hastaların hastalık derecelerine göre ayrılarak uygun olan bölüme yönlendirilmelerinin sağlanması gerekmektedir. Hastaların başvuru nedenlerine göre ayrılıp acil durumlarına göre sınıflandırılarak teşhis, tanı ve tedavi yöntemlerine göre önceliklerinin belirlenmesine triyaj denir [1]. Triyaj uygulamaları genellikle sağlık yönetim birimlerinin belirlemiş olduğu kurallar sıralamasına göre yapılmaktadır. Daha önce karşılaşılmamış bir durumda kural tablolarının yetersiz olduğu ve insan kaynaklı hatalara yol açabileceği görülmektedir.

Trijaj sistemlerinin birincil önceliği acil tıbbi yardıma ihtiyacı olan hastaları doğru ve hızlı bir şekilde belirleyebilmektir. Acil birimindeki hastaların tıbbi destek önceliklerine göre ilgili alanlara yönlendirilmesi triyaj

* Sorumlu yazar: erhanturan@ardahan.edu.tr. Yazarların ORCID Numarası: ¹ ORCID: 0000-0003-4423-0118

sistemlerinin temel hedefidir [2]. Triyaj sistemlerinin iki temel işlevi olması durumu üzerine genelleme yapılabilir [3]. Birincil işlev olarak hastanın başvuru nedeni, semptomları, öyküsü ve fiziksel muayene bilgileri alınır. İkincil işlev ise triyaj sistemi veri girişi için kayıt, direktif, öneri, değerlendirme, ambulans çıkarma, hasta ve hasta yakınlarının yönlendirilmesi, kalabalığın kontrolü ve güvenlik gibi hizmetleri içerir. Triyaj sistemleri tanılama, analiz, planlama ve değerlendirme kategorilerine göre Tip I: Trafik Yönetimi, Tip II: Aralıklı Tanılama ve Tip III: Kapsamlı Tanılama olarak üç kategoride ele alınmıştır [3]. Bu triyaj sistemleri I'den III'e gidildikçe daha kapsamlı ve sistematik bir inceleme gerektirmektedir. Trafik yönetimi triyaj sisteminde görevli personel olarak profesyonel olmayan veri giriş elemanı kullanılabilirken Aralıklı tanılamada uzman hemşire yada hekim görev yapmaktadır. Kapsamlı tanılamada ise uzman hemşire zorunluluğu vardır. Triyajda hastaları sınıflandırmak için genellikle üç aşamalı sistemler kullanılır. Bu sınıflandırma "Çok acil", "Acil" ve "Acil değil" şeklinde ayrılmaktadır [3]. Çok acil durumu hastanın anında müdahale edilmesi gerektiğini ve yaşamını tehdit eden unsurların oluşmasıdır. Acil durumu, en kısa sürede hastanın müdahaleye gerek duyduğunu ve bakıma ihtiyaç duyduğunu belirtir. Acil durumda hastanın yaşamını tehdit edecek tehditler olmasa bile akut girişimi gereklidir. Acil değil durumunda ise yaşamı tehdit edici durum gözlenmez ve rutin bakımlara yapılarak hasta bekletilebilir veya geciktirilebilir.

Hastaların acil servisi tercih etme nedeni ülkeler arası ve aynı ülke içerisinde bölgeler arası değişkenlik gösterebilmektedir. Acil bölümüne başvuranların semptomlarının acil durum sınıfı bölgeden bölgeye değişkenlik gösterebilir. Kültürel, kişisel, sosyal, ekonomik etkenler hastaların poliklinik yerine acil servislere başvurmalarına sebep olarak gösterilebilir [4]. Sıranın erken gelmesi, istenildiği zaman erişilebilmesi hastaların acil servisleri tercih etmesini sağlamaktadır. Bu nedenlerle acil bölümlerinde hasta yoğunluğu günün her anında yoğun geçebilmektedir. Risk paylaşımını kullanan triyaj uygulamalarında uygun olmayan hastalar başka birimlere yönlendirileceği için yoğunluk azaltılabilir. Düşük gelir seviyesine sahip pediatrik hastaların hastaneden geri çevrilmesi ile ilgili hastaların %40'nın yönlendirildikleri sağlık kuruluşuna başvurmadığı ortaya çıkmıştır [5].

Hastanelerin Acil bölümlerinde yoğunluğu azaltmak ve gelen hastaları risk seviyesine göre en doğru şekilde ilgili birime yönlendirmek için yapay zeka tabanlı triyaj modelleri geliştirilmektedir. Makine öğrenme tabanlı rasgele orman ağacı algoritması kullanılarak E-triage adlı bir triyaj karar destek sistem modeli eğitilmiştir [6]. Acil serviste kısa süreli taburcu edilen düşük şiddetli hastaları belirlemek için CatBoost, XGBoost, karar ağacı, rastgele orman ve lojistik regresyon algoritmalarından oluşan makine öğrenme modelleri eğitilmiştir [7]. Bu modeller eğitilirken Tayvan'daki Çin Tıp Üniversitesi Hastanesi(CMUH) ve Asya Üniversitesi Hastanesi(AUH)'nden elde edilen veriler ile gerçekleştirilmiştir. CMUH'daki 33.986 hasta için %75.9 ve AUH'daki 13.269 hasta için %82.7 daha kısa acil serviste bekleme süresi sağladığı görülmüştür. CatBoost algoritması 0.75 doğrulukla diğer makine öğrenmesi algoritmalarına göre daha yüksek başarımla elde etmiştir. Amerika Birleşik Devletlerinde büyük ölçüde öznel değerlendirmeye göre yapılan Acil Durum Ciddiyet Endeksi(Emergency Severity Index-ESI) ile makine öğrenme tabanlı geliştirilen e-triyaj uygulaması karşılaştırılmıştır [8]. Bu çalışmaya göre makine öğrenmesi ESI seviyesi 3 olan hastaları daha doğru bir şekilde sınıflandırdığı ve E-triyajın daha fazla prospektif doğrulamaya ihtiyacı olduğu gözlemlenmiştir. ön test aşamasında 16.409 hasta ve son test aşamasında 7.765 hasta verisi kullanılarak test edilen acil triyaj karar destek sisteminin heşirelerin triyaj karar doğruluğunu %57.8'den %64.9'a artırdığı gözlemlenmiştir [9].

Acil bölümlerindeki triyaj uygulamalarında ilişkisel kuralların yanı sıra öznel kararlarında etkisi yüksektir. Öznel kararlar hastaların aşırı ciddi triyaj alanına veya az önemli triyaj alanına alınmasını sağlar. Doğal dil işleme ve makine öğrenme algoritmaları kullanılarak triyaj için geliştirilen karar destek modelleri acil servis doktor kararları ile karşılaştırılmıştır [10]. CatBoost, Hafif Gradyan Artırma Makinesi(Light Gradient Boosting-LGBM), Lojistik Regresyon, Rastgele Orman, Aşırı Rastgele Ağaçlar ve Gradyan Artırma makine öğrenme algoritmaları kullanılmıştır. Rasgele Orman modeli diğer modellere göre daha yüksek başarımla sağlamıştır.


Acil Durum Ciddiyet Endeksini tahmin etmek için Karar ağacı, Rastgele orman sınıflandırıcısı, Histogram Tabanlı Gradyan Artırma sınıflandırıcısı, XGBoost sınıflandırıcısı ve ELM sınıflandırıcısı gibi Makine öğrenimi sınıflandırma algoritmaları kullanıldığı bir çalışmada hiper-parametre ayarlamaları yapılarak eğitilen modellerde Histogram Tabanlı Gradyan Artırma sınıflandırıcısı, 5 sınıfta %91'lik doğruluk sağlayarak en iyi performansı göstermiştir [11]. Bu çalışma ile açıklanabilir yapay zeka tekniklerinin akıllı sağlık uygulamaları için daha şeffaf ve güvenilir algoritmalar geliştirmek için kullanıldığı belirtilmiştir.

Japonya yapılan bir çalışmada hastane öncesi telefon triyajı için makine öğrenme modelleri geliştirilerek doğrulanmıştır [12]. Destek vektör makinesi (SVM), kement regresyonu (Lasso Regression), Rastgele orman, gradyan destekli karar ağacı (XGB) ve derin sinir ağı (DNN) tabanlı beş tahmin modeli geliştirilmiştir. 15442 hasta verileri üzerinden elde edilen modellerde RF ve XGB daha iyi performans göstermiştir. Makine öğrenme modellerinin yetersiz triyajı düzelterek doğru triyaj sınıfının tespitini hızlandırdığı ve hasta sonuçlarını iyileştirdiği görülmüştür. Telefonla alınan verilere göre yapılan triyaj karar sistemin geliştirilmesinde de makine öğrenme tabanlı yöntemler yardımcı olabildiği belirtilmiştir.

2. Materyal ve Yöntem

2.1. Metodoloji

Kural tabanlı triyaj uygulamalarında triyaj görevlisi hastayla ilgili bilgileri alarak belirlenen kurallara göre triyaj seviyesini belirlemektedir. Kural tabanlı triyaj uygulamaları artan veri türü ve miktarı, triyaj personelinin sübjektif karar vermesi nedeniyle yanlış triyaj sınıflandırmaya neden olmaktadır. Triageyi daha doğru ve hızlı hale getirmek için makine öğrenme ve derin öğrenme modelleri eğitilmektedir. Bu modeller genellikle veri seti üzerinde regresyon başarısını ölçerek değerlendirilmektedir. Bu çalışmada K-en yakın komşu, destek vektör makinesi, Gauss naif Bayes, karar ağacı, rasgele orman ve LGBM sınıflandırıcıları kullanılarak model eğitimleri gerçekleştirilmiştir. Bu modellerin gerçek dünya problemi olan triyaj karar destek sisteminde kullanılabilmesi için grafiksel arayüz(GUI) geliştirilmiştir. Triage personeli GUI üzerinden girdiği hasta bilgilerini girerek triyaj sınıflandırmasını yapabilmektedir. Geliştirilen triyaj karar destek sisteminin akış şeması Şekil 1’de verilmiştir.



Şekil 1. Triage karar destek sistemi akış şeması

Şekil 1’de verilen akış şemasında görüldüğü gibi veri seti kategorilendirilerek ön işleme aşamasından sonra makine öğrenme modelleri üzerinde eğitilir. Eğitilmiş modeller geliştirilen GUI’ye verilerek GUI üzerinden Triage verisinin test işlemi yapılarak hastanın triyaj kategorisi belirlenir.


2.2. Veri Seti

Acil servislere başvuran hastalardan istenilen veri ve acil birimlerine başvuran hasta sayısındaki artış doğru triyayı gerçekleştirebilmeyi zorlaştırmaktadır. Makine öğrenme algoritmaları veri büyüdükçe daha doğru genelleme yapabilir. Bu nedenle triyaj karar destek sistemleri geliştirilmekte ve giderek daha kapsamlı uygulamalar, servisler ortaya çıkmaktadır. Makine öğrenme algoritmalarının çalışabilmesi için en önemli girdi parametresi doğru yapılandırılmış veridir. Acil birimlerinde elde edilen semantik veriler ön işleme aşamasıyla kategorilendirilerek makine öğrenme sınıflandırıcılarının anlayacağı matematiksel girdilere dönüştürülmelidir. Bu çalışmada Kore’deki yerel ve bölgesel hastanelerinden elde edilen Kore Triage ve Akutluk Ölçeği (The Korean Triage Acuity Scale-KTAS) adlı veri seti kullanılmıştır [13], [14]. Bu veri seti 24 özellik ve 1267 hasta kaydı içermektedir. KTAS veri setini oluşturan özellikler ve bu özellikleri oluşturan değerlerin kategorik yapıları Tablo 1’de verilmiştir.


Tablo 1. KTAS veri seti özellikleri

Özellik	Değer	Özellik	Değer
Grup	1: Yerel Acil Servis / 2: Bölgesel Acil Servis	Yaralanma	1: Yaralanma yok 2: Yaralanma var
Cinsiyet	1: Kadın / 2: Erkek	Mental Durum	1: Uyanık 2: Sözel yanıt 3: Ağrıya yanıt 4: Bilinçsizlik
Yaş	Yaş (Yıl)	Ağrı	1: Ağrı var 2: Ağrı yok
Saat Başı Hasta Sayısı	Hasta sayısı / saat	NRS_ağrı	Sayısal ağrı derecelendirme skalası
Varış Yöntemi	1: Yürüyerek	SBP	Sistolik kan basıncı
	2: Ambulans	DBP	Diastolik kan basıncı
	3: Özel araba	HR	Kalp atım hızı
	4: Özel ambulans	RR	Solunum sayısı
	5: Toplu taşıma (Polis vb.)	BT	Vücut sıcaklığı
	6: Tekerlekli sandalye	Saturasyon	Pulse oksimetre ile ölçülen saturasyon
	7: Diğerleri		
KTAS_Hemşire	Acil serviste hemşire tarafından verilen KTAS sonucu	KTAS_Uzman	Uzman tarafından verilen KTAS sonucu
Taburcu Durumu	1: Taburcu	Hata Grubu	1: Hayati bulgular
	2: Servis yatışı		2: Fizik muayene
	3: Yoğun bakım yatışı		3: Psikiyatrik
	4: Kendi isteğiyle çıkış		4: Ağrı
	5: Transfer		5: Mental
	6: Ölüm		6: Altta yatan hastalık
	7: Acil servisten ayaktan tedavi		7: Başka acil servis kaydı
Kalış Süre (dakika)	Kalınan süre (dakika)	KTAS Süre (dakika)	KTAS işlemi süre (dakika)
Triage	0: Doğru - 1: Aşırı triage - 2: Eksik triage		


Tablo 1’de verilen KTAS veri seti makine öğrenme modellerinde eğitilmek üzere %80 eğitim ve %20 test verisi olarak kullanılmıştır. KTAS veri setine ait 1267 hasta verisinin grafikleri Şekil 2, Şekil 3 ve Şekil 4’te verilmiştir.



Şekil 2. KTAS veri seti özellik kategori grafikleri I



Şekil 3. KTAS veri seti özellik kategori grafikleri II



Şekil 4. KTAS veri seti özellik kategori grafikleri III

Şekil 2, Şekil 3 ve Şekil 4’te verilen veriler kategorilendirilerek sayısallaştırma işlemi veri ön işleme aşamasını oluşturur. Bu işlemler ile birlikte makine öğrenme sınıflandırıcıları için anlamlı ve daha uygun veri formatı elde edilir. Bu çalışmada eksik değer analizi, özellik mühendisliği ve aykırı değer analizi sırasıyla veriye uygulanarak hedef veri seti oluşturulur. Eksik değer analizinde, veri setinde boşluklar tespit edilmektedir. Tespit edilen boşluklar koşullu mod doldurma işlemi kullanılarak doldurulur. Koşullu mod doldurma ile boşluklar boşluğun ait olduğu özelliğin en sık tekrar eden değeriyle doldurulmaktadır. Bu yöntem rasgele doldurmaya göre daha bağlamsal tahmin yapabilmeyi sağlar. Özellik mühendisliği kısmında veriler üzerinde dönüşümler yapılarak sayısal hatalar düzeltilerek veriler daha anlamlı hale getirilmiştir. Kalış süresi ve NRS ağrı derecelendirme skalası için veri setinde olan virgül ve noktalar atılarak Integer formatına dönüştürülmüştür. Bu sayede veri tipi uyumsuzlukları düzeltilmiştir. SBP, DBP gibi özelliklerde bulunan hatalı String verileri 0.0 ile değiştirilerek Float formatına dönüştürülmüştür. Cinsiyet, yaralanma, zihinsel, grup, varış modu, eğilim, KTAS_RN, KTAS uzmanı gibi özelliklere ait veriler sayısal verilerle temsil edilmesine rağmen kategorilendirilerek daha yorumlanabilir hale dönüştürülmüştür. Yaş özelliği genç, yetişkin, orta yaş ve yaşlı olmak üzere dört kategoriye ayrılmıştır. SBP, DBP, HR, RR, BT, NRS ağrı gibi fizyolojik özellikler ise analitik olarak düşük, normal ve yüksek gibi kategorilere dönüştürülmüştür. Bu dönüşüm işlemleri özellikler ile sonuç arasında doğrusal olmayan ilişkileri bulmayı ve sınıflandırıcıların yorumlanmasını kolaylaştırır. Aykırı değer analizinde veri setinde bulunan uç noktalar tespit edilerek sınıflandırma modeline etkisinin azaltılması sağlanmıştır. Yüzdebirlik tabanlı eşik değerleri kullanılarak belirli eşik değerleri dışında kalan değerler aykırı değer olarak kabul edilir. Aykırı değerler alt veya üst limitle değiştirilerek güncellenir. Bu işlem Winsorizasyon olarak bilinmektedir. Minimum kalma süresi, Saturasyon, RR ve BT özelliklerine Winsorizasyon işlemi uygulanmıştır.

Kapsamlı veri ön işleme adımlarıyla veri kalitesi artırılmaktadır. Bu sayede daha genellenebilir, doğru ve hızlı tahmin üretebilen modellerin eğitilmesi amaçlanır.

2.3. Makine Öğrenme Sınıflandırıcıları

2.3.1. K- En Yakın Komşu

K-en yakın komşu algoritması denetimli veri kullanan bir sınıflandırıcı ve regresyon algoritmasıdır. Bir verinin ait olduğu sınıf tahmin edilmek istendiğinde eğitim verisindeki tüm örneklerle göre Öklid mesafesi hesaplanır. K tane komşu verinin sınıfının çoğunluk sınıfı belirlenerek verinin sınıfı olarak etiketlenir. Bu işlemdeki en önemli parametrelerden biri k sabitidir. Bu değerin büyük olması modelin daha geniş alandaki kümeyi tarayarak daha genel bir eğitim yapılmasını sağlar [15]. Bu durum doğruluk ve genellemeyi artırırken hesaplama süresini de beraberinde uzatır. Genelleme doğruluğu ve süre arasında optimal denge geliştiriciye bağlıdır. Çalışma kapsamında Scikit-learn kütüphanesinin “KNeighborsClassifier” adlı nesnesi ile triyaj veri seti üzerine KNN sınıflandırıcısı uygulanmıştır. Bu sınıflandırıcı ile model eğitimi yapılırken tanımlı değerler olan komşu sayısı k=5, uzaklık metriği ise Minkowski olarak ayarlanmıştır. Minkowski parametresi olarak 2 verildiği için Öklid uzaklık hesabına göre KNN çalışır. P parametresinin 2 olarak ayarlandığı durumda iki nokta arasındaki uzaklıkların toplamı olan Minkowski uzaklığı Denklem 1’de verilmiştir.

$$\text{Minkowski mesafesi} = (\sum_{i=1}^n |x_i - y_i|^p)^{\frac{1}{p}} \quad (1)$$

Denklem 1’de verilen Minkowski mesafesine göre en yakın k adet komşu belirlenir. Bu k adet komşunun hangi sınıflara ait olduğu belirlenir. Komşuların ait oldukları sınıf y_i ile gösterilir. En çok sınıfa ait olan komşuların sınıfı noktanın tahmini sınıfı olarak atanır. Noktaya sınıf atama işlemi Denklem 2’de verildiği gibidir.

$$y = \text{argmax } y_i \quad (2)$$

2.3.2. Destek Vektör Makinesi

Destek vektör makinesi(Support Vector Machine-SVM) birbirlerine en yakın noktaları belirleyerek bu noktaları ayıran eğriye dik uzaklığı maksimum yapmaya çalışır. Sınıflandırma fonksiyonunun bütün sınıflara eşit uzaklıkta olmasını hedefler. Doğrusal ayrılamayan sınıflar için sınıflandırma fonksiyonunu değiştiren çekirdek tipleri kullanılarak çoklu sınıflar daha optimal şekilde sınıflandırılabilir. Çekirdek tipleriyle birlikte temelde ikili sınıflandırma için kullanılan SVM, çoklu sınıflar içinde kullanılabilir hale getirilebilmektedir. İkili sınıflarda doğrusal çekirdeklerin seçimi daha hızlı ve doğru sonuçlar verebilmektedir. Veri setindeki sınıflar doğrusal olarak ayrılmadığı durumlarda Gauss, Hiperbolik, Polinomal, RBF ve Puk gibi çekirdekler kullanılarak sınıflandırma yapılabilir [16]. Bu çalışmada RBF çekirdek tercih edilmiştir. SVM kullanılan gamma sabiti otomatik olarak ayarlanan Denklem 3’te verilen fonksiyonla elde edilmiştir.

$$\text{Gamma} = \frac{1}{\text{Özellik sayısı}} \quad (3)$$

Denklem 3’te verilen gamma değeri SVM fonksiyonunun aşırı öğrenme veya yetersiz uyumunu engellemek için kullanılır. Büyük gamma değeri aşırı öğrenmeye yaklaştırırken düşük gamma değeri ise yetersiz öğrenme sağlar. SVM’de kullanılan bir diğer parametrede C değeridir. C değeri sınıflar arası maksimum mesafeyi belirtir. C değeri 0 ile 1 aralığındadır. 1 olduğu durumda sınıflar arası mesafe minimum yapılması hedeflenir. Bu çalışmada C değeri olarak 1 alınmıştır. C değerinin 1 olarak ayarlanması modelin daha fazla nokta üzerinde karşılıklı sınıflandırma fonksiyonunu oluşturacağını belirtir. Verileri doğrusal olarak iki sınıftan sonra zorlaşmaktadır. Verileri daha hassas bir şekilde ayırmak için SVM çekirdekleri devreye girmektedir. x sınıflandırılacak yeni veriyi, x_i bir destek vektörünü yani eğim noktasını, y_i değeri x_i destek vektörünün gerçek sınıfını, a_i destek vektörünün önemini belirten ağırlık katsayısını, b bias(sapma) değerini $K(x_i, x)$ çekirdek fonksiyonunu temsil etmektedir. Bu temsillere göre sınıflandırma fonksiyonu Denklem 4’te verilmiştir.

$$f(x) = \text{sign}(\sum_{i \in SV} a_i y_i K(x_i, x) + b) \quad (4)$$

Denklem 4’te verilen sınıflandırma fonksiyonuna göre $f(x)$ işaretine bakarak noktanın hangi sınıfa ait olduğu belirlenir.

2.3.3. Naif Bayes

Olasılıksal bir sınıflandırıcı olan Naif Bayes, veri setini oluşturan özellikleri birbirinden bağımsız tutarak verileri sınıflandırmayı amaçlamaktadır. Naif Bayes algoritması her özelliğin birbirinden bağımsız olduğunu ancak sınıfın bu özelliklere bağlı Bayes ağı modelidir. Naif bayes sınıflandırıcısı tıbbi karar verme süreçlerinde sıklıkla kullanılmaktadır [17]. Az veri kullanarak sınıflandırma yapabilen Naif bayes genellikle hızlıdır. Bu hız gerçek zamanlı karar verme sürecini barındıran tıbbi karar destek sistemlerinde kullanılmaktadır. Bu çalışmada kullanılan veri集中的 özellikler sürekli değerler olarak normal Gauss dağılımına uyduğundan Gaussian Naif Bayes kullanılmıştır. Bayes sınıflandırıcısının özelliğe göre sınıf hesaplama olasılık fonksiyonu Denklem 5'te verilmiştir.

$$P(\text{sınıf} | \text{veri}) = \frac{P(\text{veri} | \text{sınıf}) * P(\text{sınıf})}{P(\text{veri})} \quad (5)$$

Denklem 5'te $P(\text{sınıf} | \text{veri})$ değeri verinin belirli bir sınıfa ait olma olasılığını belirtir. $P(\text{veri} | \text{sınıf})$ değeri verinin o sınıf içinde olma olasılığını temsil eder. $P(\text{sınıf})$ değeri sınıfların genel olasılığını belirtir. Son olarak $P(\text{veri})$ ise verinin sınıftan bağımsız olarak görünme olasılığını temsil eder. Gaussian Naive Bayes en yüksek olasılığı veren fonksiyona göre sınıflandırmayı gerçekleştirir. y Gaussian Naive Bayes modelinin tahmin ettiği sınıfı, argmax_k Parantez içindeki değeri en yüksek yapan k değerini, $P(C_k)$ C_k sınıfının olasılığını, x n adet özelliğe sahip giriş verisini, $P(x_i, C_k)$ ise C_k sınıfı içinde x_i özelliğinin görülme olasılığıdır. Bu temsillere göre sınıflandırma fonksiyonu Denklem 6'da verilmiştir.

$$y = \text{argmax}_k P(C_k) \prod_{i=1}^n P(x_i, C_k) \quad (6)$$

2.3.4. Karar Ağacı

Karar ağacı (Decision Tree-DT) algoritması veri集中的 özelliklere göre kurallar belirleyerek veriyi sınıflandırmayı amaçlayan bir akış modelidir. Veriyi sınıflandırmak için her düğümde eğer ise sorusuna verilen yanıtı göre sınıflandırma yapılır. DT, kök düğüm, karar düğümü, dal ve yaprak düğümünden oluşan dört temel elemana sahiptir. Kök düğüm ağacın en üstündeki başlangıç düğümüdür. Karar düğümü, verinin en az iki sınıfa bölündüğü düğümdür. Dallar düğümlerden çıkan cevap niteliğinde olan yollardır. Yaprak düğüm ise ağacın en sonunda bulunan karar düğümüdür. Karar ağacının her düğümü veri setinde bulunan bütün elemanları kendi sınıfına ait olana kadar ayırmaktır. Bütün sınıflar en saf hale gelene kadar karar ağacındaki düğümlere yeni karar düğümleri eklenebilir [18]. Algoritmanın temel amacı veriyi en saf hale getiren özelliği belirleyerek karar düğümünde kullanmaktır. Karar düğümünde kullanılan özellik belirlenirken Entropi, bilgi kazancı veya Gini safsızlığı kullanılır. Entropi ve Gini verideki belirsizliği ölçmek için kullanılır. Entropi bir verideki belirsizliğin ölçüsüdür. Entropi verisinin değerlendirme işlemi Denklem 7'de verilmiştir.

$$\text{Entropi} = \begin{cases} 0 & (\text{Tam saflık, gruptaki tüm veriler aynı sınıfa ait}) \\ 0 < \text{Entropi} < 1 & \\ 1 & (\text{Maksimum kirlilik, gruptaki bütün veriler sınıflarda eşit miktarda bulunur}) \end{cases} \quad (7)$$

DT'lerde kullanılan Gini safsızlığı Entropiye alternatif olarak kullanılan bir belirsizlik ölçüsüdür. Bir gruptan alınan bir örneğin veri集中的 dağılımına göre yanlış sınıflandırılma olasılığının ölçüsüdür. Hesaplanması hızlı olduğundan büyük veri setlerinde hızlı çalışır. Bu çalışmadaki triyaj verisini sınıflandıran DT modeli için Gini belirsizlik ölçüsü kullanılmıştır. DT'nin daha doğru model eğitimi sağlamak için maksimum derinlik için bir sınır belirlenmemiştir. Gini skorunun 0 olması mükemmel saflığı temsil eder. Bu durumda düğümdeki tüm verilerin aynı sınıfa ait olduğu söylenir. k toplam sınıf sayısını ve p_i ise i sınıfının bu düğümdeki olma olasılığını belirtmektedir. Bu temsillere göre Gini skoru Denklem 8'de verilmiştir.

$$\text{Gini}(D) = 1 - \sum_{i=1}^k (p_i)^2 \quad (8)$$

2.3.5. Rasgele Orman Ağacı

Rasgele orman ağacı birden fazla karar ağacının bir araya gelerek toplu tahmin yapabilme prensibine dayanır. Karar ağacına göre tek bir model üzerinden değil birden fazla model üzerinden sınıf tahmini yapılabildiğinden daha genellenebilir sonuçlar üretmektedir. Rasgele orman ağaçları karar ağacı, bagging ve özellik rasgeleliği olmak üzere üç yapıdan oluşur [19]. Karar ağaçlarının eğitildiği veri setindeki özellik sayısı arttıkça karar ağaçları ezberlemeye yatkınlaşır. Ezberleme sorununu çözmek ve daha genellenebilir sınıflandırıcılar oluşturmak için bagging tekniği kullanılır. Bagging işlemi ile veri setinden rasgele veriler seçilerek alt veri setleri oluşturulur. Veri setinden bazı noktalar birkaç kez ve bazı yerler ise hiç kullanılmayarak alt veri setleri oluşturularak bu alt veri setlerinden bağımsız karar ağaçları elde edilir. Rasgele orman ağacı kendi özellik rasgeleliğiyle sadece verileri değil karar ağacında kullanacağı özellikleride rasgele seçerek genel bir karar verme modeli üretmeyi amaçlar. Karar ağacının her düğümünde en iyi ayrımı yapan özellik yerine özellik alt kümesi seçilerek bu alt küme içerisinde en iyi dallanmayı yapabilen özelliği seçmektedir. Özellik rasgeleliği ile karar ağaçları arasındaki ilişki azaltılarak daha genel tahminlerin yapılması sağlanır. Bu çalışmada kullanılan rasgele orman ağacındaki karar ağaçları için Gini belirsizlik ölçüsü kullanılmıştır. Ormandaki ağaç sayısı maksimum 100 olarak ayarlanmıştır. Maksimum derinlik için ise sınır belirlenmemiştir. Rasgele Orman algoritmasında karar ağaçlarının oylaması sonucunda çoğunlukla elde edilen sonuca göre sınıf tespiti yapılmaktadır. $H(x)$ verinin sınıf kararını, C olası bütün sınıfları, $\argmax c \in C$ en çok oyu alan sınıfı, K ormandaki toplam karar ağacı sayısını, $h_k(x)$ k.karar ağacının x girişine karşı yaptığı çıkış tahminini ve I göstege fonksiyonunu (tahmin doğru ise 1 yanlış ise 0) temsil eder. Bu temsillere göre Rasgele Orman Ağacının sınıflandırma fonksiyonu Denklem 9’da verilmiştir.

$$H(x) = \argmax c \in C (\sum_{k=1}^K I(h_k(x) = c)) \quad (9)$$

2.3.6. LGBM


Light Gradient Boosting Machine (LGBM) Gradyan artırma çatısına göre çalışan büyük veri setlerinde hesaplama verimliliği ve ölçeklendirmeyi optimize edebilmek için geliştirilen bir karar ağacı tabanlı topluluk algoritmasıdır. Gradyan artırmanın temel amacı karar ağacı gibi basit karar sınıflandırma ve tahmin modellerini ardışık olarak birleştirerek daha genellenebilir karar modelleri oluşturmaktır. Gradyan artırımı hataları izleyerek ders çıkarma üzerine kendini geliştirmektedir. Bu şekilde her adımda önceki model hatasını düzelterek yeni modeli eğitir. Bu işlemler tekrarlamalı bir şekilde yürütülerek her eğitilen yeni model topluluğun genel başarımını iyileştirmeye odaklanır [20]. Gradyan artırma algoritması başlangıç tahmini, hataların hesaplanması, hataya odaklı yeni model, model güncellemesi ve yineleme adımları olmak üzere beş adımdan oluşur. Her model bir önceki modelin eksik yönlerini iyileştirmeye çalıştığından ortaya çıkan toplu model daha genellenebilir ve performanslı sonuçlar üretebilmektedir. LGBM özellikleri ayrılaştırarak bölünme noktası bulmayı hızlandıran histogram tabanlı algoritma ve kayıp fonksiyonun azalmasını sağlayan en etkili yaprağı seçerek ağacı büyütmeyi sağlayan yaprak tabanlı bir büyüme stratejisini kullanmaktadır. Bu çalışmada öğrenme oranı [0.01, 0.1], güçlendirilecek ağaç sayısı [200,500, 1000], maksimum ağaç derinliği [3,5,8] ve her ağacı oluşturan sütunların at örnek oranı [1, 0.8, 0.5] olarak Python tabanlı “lightgbm” kütüphanesi üzerinden belirlenerek eğitilmiştir. LGBM’de hata Logaritmik Kayıp (Log Loss) ile ölçülmektedir. N örnek verilerin sayısını, K sınıf sayısını, y_{ik} i. örneğin k. sınıfa ait olma durumunu (1 evet, 0 hayır) ve p_{ik} ise i. örneğin k. sınıfa ait olma olasılığının tahmini değerini belirtir. İkili sınıflandırmanın çoklu sınıflandırmaya uyarlanmış hali Denklem 10’da verilmiştir.

$$L(Y, P) = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_{ik} * \log p_{i,k} \quad (10)$$

3. Deneysel Sonuçlar


Makine öğrenme tabanlı triyaj karar destek sisteminin uygulanabilmesi için grafiksel arayüz tabanlı bir masaüstü uygulama yazılımı geliştirilmiştir. Son kullanıcı tarafından hastadan alınan temel triyaj bilgilerinin sisteme girilmesini sağlayan uygulama Şekil 5’te verilmiştir.

Makine Öğrenme Tabanlı Hastane Triyaj Karar Destek Sistemi Uygulamasının Geliştirilmesi




Şekil 5. Triyaj karar destek sistemi masaüstü uygulaması

Şekil 5'te verilen uygulamada arayüzün sol tarafında fizyolojik ve demografik bilgiler hastadan alınmaktadır. Orta kısımda hastanın sürekli değişkenlik gösteren verileri kategorik sınıflara ayrılarak veriler alınmaktadır. Bu verilere ilave olarak bu kısımda KNN, SVM, GNB, DTC, RF ve LGBM sınıflandırıcılarından elde edilmiş triyaj modellerinin eğitilmiş model seçimlerinin yapıldığı alan bulunmaktadır. Sınıflandırıcılar Python ve Scikit-Learn kütüphanesi kullanılarak ".pkl" dosya uzantılı şekilde model eğitimi yapılmıştır. Bu sayede altı sınıflandırıcının aynı veri setindeki performansını kıyaslayarak gerçek zamanlı test verisinde karşılaştırma yapma imkanı sunmaktadır. Modellerin test işlemleri sonucunda elde edilen karışıklık matrisi Şekil 6'da verilmiştir.



Şekil 6. Triyaj model karışıklık matrisleri

Şekil 6’da verilen makine öğrenme modellerine ait performans sonuçlarına göre, LGBM ve RF hem çoğunluk sınıfı olan "Normal Triyaj" kategorisinde hem de diğer sınıflarda en yüksek doğruluk tahmin değerlerine ulaşmıştır. Buna karşın, SVM KNN algoritmaları normal triyaj sınıfını başarıyla tahmin etse de, modelin genelleme yeteneğini düşürecek şekilde "Trijaj Üstü" gibi azınlık sınıflarda belirgin bir şekilde başarısız performans sergilemiştir. Özellikle GNB modelinin, çoğunluk olan "Normal Triyaj" vakalarını yanlış sınıflandırarak mevcut veri seti üzerinde genelleme yapamadığı görülmektedir. Modellerin test validasyon doğrulukları grafiksel arayüzün sağ tarafında verilen sütun grafikler karşılaştırılabilmektedir. Sınıflandırıcıların test doğruluk, kesinlik, geri çağırma ve F1 skorunu içeren grafik Şekil 7’de verilmiştir.



Şekil 7. Triyaj model değerlendirme metriklerinin karşılaştırılması

Şekil 7’de görüldüğü gibi RF modeli LGBM ile birlikte %96.1 test doğruluğu ile en yüksek performansı sunmuştur. Modellerin performansı değerlendirilirken yalnızca doğruluk oranıyla yetinilmeyerek; sınıflar arası dengesizliklerin model üzerindeki etkisini gözlemleyebilmek amacıyla Şekil 6’da sunulan karışıklık matrisleri ile Şekil 7’de detaylandırılan kesinlik, geri çağırma/duyarlılık ve F1-skoru gibi çok yönlü ölçütler de analiz edilmiştir. Karışıklık matrisleri incelendiğinde, özellikle LGBM ve RF modellerinin yalnızca çoğunluk sınıfı olan Normal Triyaj(sarı alan) vakalarını değil, tespiti daha kritik olan azınlık sınıflarını Triyaj Altı(yeşil alan) ve Triyaj Üstü(kırmızı alan) yüksek hassasiyetle ayırabildiği görülmektedir. Şekil 7 verilerine göre, RF ve LGBM modelleri %96.1 doğruluk oranının yanı sıra, %96.2 kesinlik ve %96.1 geri çağırma skorlarına ulaşmaktadır. F1-skorunun %95.1 seviyesinde gerçekleşmesi, modellerin yanlış pozitif ve yanlış negatif tahminleri başarılı bir şekilde minimize ettiğini ve farklı triyaj sınıfları arasında kararlı bir tahmin yeteneği sergilediğini kanıtlamaktadır. RF ve LGBM modelini %95.3 test doğruluğu ile SVM takip etmektedir. Orta performans olarak gösterebileceğimiz KNN ve DTC %87 civarı test doğruluğu sunmaktadır. Son olarak GNB ise %6 test doğruluğu ile bu test verisi için kullanılmayacağı görülmektedir. Genel olarak bu sonuçlar değerlendirildiğinde, topluluk tabanlı sınıflandırıcı olan RF ve LGBM’nin triyaj karar destek sisteminde daha yüksek doğruluk sağlayarak daha iyi genelleme yapabildiğini göstermektedir. RF modeli LGBM modelleri 0.96 seviyesinde kesinlik ve geri çağırma değerleriyle dengeli bir tahmin yeteneği sergilemişlerdir. GNB modeli ise 0.902 seviyesinde yüksek kesinliğe sahip olmasına rağmen aşırı düşük 0.063 geri çağırma skoru ile gerçek pozitif sınıfını tespit etmede zaafiyet göstermiştir.

Uygulama arayüzünde hastadan alınan triyaj verileri sisteme girildiğinde ve test edilecek sınıflandırıcı modeli seçildikten sonra “SINIFLANDIR” butonu ile hastanın tedavi göreceği alan belirlenmektedir. Bu alan KTAS veri setinde under triage, normal triage ve over triage olarak sırasıyla yeşil, sarı ve kırmızı alandan biri olacak şekilde belirlenmektedir. Bu şekildeki bir karar mekanizması uygulamanın gerçek zamanlı olarak çalışabildiğini göstermektedir. Uygulama arayüzünün alt kısmında ise KTAS veri setindeki özellik ve veriler yer almaktadır. Bu veriler kullanılarak sınıflandırıcı modellerinin eğitildiği gösterilmektedir. Bu veri setinde hata (error) ve yanlış triyaj (mistriage) özelliklerinin bulunması sınıflandırıcıların hata analizi ve yanlış sınıflandırma oranlarında

detaylandırıldığını göstermektedir. Bu özelliklerden yola çıkarak her sınıflandırıcı her triyaj verisine göre kesinlikle üç triyaj kategorisinden birini seçemeyebilir. Bu durumda sınıflandırıcı hata çıktısını üretebilir. Bu veri ve bulgulara dayanarak makine öğrenme tabanlı triyaj karar destek sisteminin acil servislerde doğru, tutarlı ve hızlı triyaj kararlarının verilmesini artırma potansiyeli gösterdiği ve özellikle RF, LGBM ve SVM'nin triyaj modeli için uygun olduğu kanıtlanmıştır. Literatürde yapılan çalışmalar Tablo 2'de karşılaştırılarak verilmiştir.

Tablo 2. Literatür triyaj çalışmaları karşılaştırması

Makale	Kullanılan Model	Veri Seti	Test Doğruluğu
[21]	Deep Neural Network (DNN), Gradient Boosting, XGBoost	Yerel hastane acil servis kaydı	AUC: 0.86 (Kritik bakım tahmini), AUC: 0.82 (Yatış tahmini)
[22]	XGBoost	Yerel hastane acil durum verisi	Doğruluk: %82.57 , AUC: 0.91 - 0.96 (Kategori bazlı)
[23]	Gradient Boosting (GB)	MIMIC-IV-ED (400.000+ acil servis ziyareti)	Doğruluk: %83.0 , Duyarlılık: %82.0, Özgüllük: %84.0
[24]	Gradient Boosting, Random Forest, YSA, Lojistik Regresyon	Lampang Hastanesi ED verisi (45.245 kayıt)	Doğruluk: %81.0 (Gradient Boosting Modeli)
[25]	XGBoost, Lojistik Regresyon	Yale New Haven Hastanesi	AUC: 0.87 (XGBoost ile yatış tahmini)
Bizimki	KNN, SVM, GNB, DTC, RF ve LGBM	KTAS	Doğruluk: %96.1 (LGBM ve RF)

Tablo 2'de verilen benzer makine öğrenme tabanlı triyaj çalışmalarında genel olarak %81.0 ile %83.0 bandında doğruluk oranlarına ulaşıldığı görülmüştür. Bu çalışmada KTAS veri seti ile eğitilen LGBM ve RF modelleri %96.1 test sınıflandırma doğruluk seviyesine çıkarak belirgin bir başarı artışı sağlamıştır. Elde edilen bu doğruluk değeri ile GUI tabanlı triyaj uygulaması klinik ortamlarda güvenilir bir karar destek sistemi olarak görev yapabileceği kanıtlanmaktadır.

3.1. Kısıtlar ve Model Genellenabilirliği

Çalışmada kullanılan KTAS veri setinde 1267 hasta kaydı mevcuttur. Bu veri seti literatürde triyaj tabanlı karar destek sistem modellerinde sıklıkla kullanılmıştır. Orta çaplı bir dev hastanenin acil servisine gelen hasta sayısı düşünüldüğünde 1267 hastaya ait veriler yüksek genellemeli makine öğrenmesi modelleri için yeterli olmayabilir. Bu durum küçük veri setlerinde sıkça karşılaşılan aşırı öğrenme riskini gündeme getirmektedir. Bu çalışmada aşırı öğrenme riski, makine öğrenmesi algoritmalarının doğası gereği barındırdığı mekanizmalarla en aza indirgenmiştir. Rastgele Orman (RF) modelinde kullanılan torbalama tekniği ve özellik rastgeleliği, her bir karar ağacının veri setinin farklı alt kümelerinde eğitilmesini sağlayarak modelin eğitim verisini ezberlemesini engellemiştir. Benzer şekilde, LGBM modelinde uygulanan hiper-parametre optimizasyonları ve yaprak tabanlı büyüme stratejisi, modelin genelleme yeteneğini güçlendirmiştir. Veri ön işleme aşamasında aykırı değerlerin etkisini azaltmak için uygulanan eksik veri tamamlama adımları da model kararlılığına doğrudan katkı sağlamıştır.

Aşırı öğrenmeden kaçınmak için kullanılabilecek bu tekniklere rağmen, elde edilen başarılı sonuçların farklı demografik ve kültürel özelliklere sahip hasta popülasyonlarında genellenebilirliğini kesin olarak kanıtlamak adına, gelecekteki çalışmalarda uygulamanın daha büyük ölçekli ve çok merkezli klinik veri setleri üzerinde çapraz doğrulama testlerine tabi tutulması hedeflenmektedir.

4. Sonuçlar

Bu çalışma sürecinde acil servis ünitelerindeki triyaj işleminin verimliliğini ve doğruluğunu artırmak için makine öğrenme tabanlı bir karar destek sistemi geliştirilerek deneysel testleri yapılmıştır. Açık kaynak olan Kore'deki bir yerel ve ulusal hastanenin acil servis verileri kullanılarak DT, GNB, KNN, LGBM, RF ve SVM makine öğrenme modelleri eğitilmiştir. Eğitilen bu modellerin hastane ortamında kullanımının sağlanabilmesi için Java swing kütüphanesi kullanılarak bir grafiksel arayüz uygulaması geliştirilmiştir. Elde edilen eğitim modellerinin test sonuçlarına topluluk tabanlı sınıflandırıcıların daha yüksek başarımla sağladığı görülmüştür. %96.1'lik bir başarımla en iyi test sonucunu RF ve LGBM modeli vermiştir.

Genel bulgular değerlendirildiğinde RF, LGBM ve SVM modelleri triyaj karar destek sistemlerinde iş yükü yoğunluğunu azaltma ve insan kaynaklı hataları azaltarak gelen hastaların doğru birime yönlendirilmesinde önemli bir potansiyel sunmaktadır. Literatürde acil servis triyaj sistemleri üzerine yapılan benzer çalışmalar incelendiğinde, XGBoost, Gradient Boosting ve YSA gibi yöntemlerle genellikle %81.0 ile %83.0 bandında doğruluk oranları elde edildiği görülmektedir. Bu çalışmada geliştirilen LGBM ve RF tabanlı karar destek sisteminin ulaştığı %96.1 doğruluk seviyesi, literatürdeki mevcut araştırmalara kıyasla belirgin ve yenilikçi bir performans artışı temsil etmektedir. Sistemin klinik ve pratik etkileri değerlendirildiğinde; acil servis gibi stres faktörünün ve yoğunluğun yüksek olduğu birimlerde sağlık personelinin öznel yargılarından kaynaklanan triyaj hatalarının ciddi oranda azaltılabileceği öngörülmektedir. Geliştirilen GUI, triyaj görevlisine anlık olarak ikincil bir doğrulama ve rehberlik mekanizması sunarak karar verme sürecini hızlandırmaktadır. Hastaların en doğru birimlere yönlendirilmesi yalnızca acil sağlık hizmeti bekleyen kişilerin yaşam güvenliğini artırmakla kalmayarak; aynı zamanda yatak kapasitelerinin, uzman hekim mesaisinin ve tıbbi kaynakların en verimli şekilde kullanılmasına olanak sağlamaktadır. Bu kaynakların verimli kullanılması hastanelerin idari ve ekonomik yüklerini de önemli ölçüde hafifletmektedir.

Geliştirilen makine öğrenme modelleri ve bu modellerle entegre çalışan grafiksel arayüz ile acil servislerde daha hızlı ve tutarlı kararların verilmesi sağlanacaktır. Bu sürecin insani sağlık boyutunun yanı sıra ekonomik boyutu da göz ardı edilmemelidir. Yanlış alana gönderilen her hastanın ülke ekonomisine zararı düşünüldüğünde triyaj karar destek sistemlerinin hızlı bir şekilde hastanelerde kontrolü insandan alıp makineye vereceği beklenmektedir.

Kaynaklar

- [1] N. Akyolcu, "Acil Birimlerde Triage," *Florence Nightingale J. Nurs.*, vol. 15, no. 58, 2014.
- [2] H. Kırmızıgül, A. Erciyas, N. Görmeli Kurt, and Y. Kavak, "Acil Bakım Hemşirelerinin Triage Karar Verme Becerilerinin Değerlendirilmesi," *İnönü Üniversitesi Sağlık Hizmetleri Mesl. Yüksek Okulu Derg.*, vol. 12, no. 3, pp. 967–978, 2024.
- [3] Bracken J, *Triage. Newberry L (Ed). Emergency Nursing*, 5th ed. 2003.
- [4] D. Öner Şimşek, "Triage Sistemlerine Genel Bakış Ve Türkiye'de Acil Servis Başvurularını Etkileyen Faktörlerin Lojistik Regresyon İle Belirlenmesi," *Sos. Güvence*, No. 13, Pp. 84–115, 2018.
- [5] R. M. Williams, "Triage and emergency department services," *Annals of emergency medicine*, vol. 27, no. 4. United States, pp. 506–508, Apr-1996.
- [6] Ş. Bora *et al.*, "Machine Learning for E-triage," *Int. J. Multidiscip. Stud. Innov. Technol.*, vol. 6, no. 1, pp. 86–90, 2022.
- [7] Y.-H. Chang *et al.*, "Machine learning-based triage to identify low-severity patients with a short discharge length of stay in emergency department," *BMC Emerg. Med.*, vol. 22, no. 1, p. 88, 2022.
- [8] S. Levin *et al.*, "Machine-Learning-Based Electronic Triage More Accurately Differentiates Patients With Respect to Clinical Outcomes Compared With the Emergency Severity Index," *Ann. Emerg. Med.*, vol. 71, no. 5, pp. 565-574.e2, May 2018.
- [9] S. B. Çetin, F. Cebeci, and O. Eray, "The effect of computer-based decision support system on emergency department triage: Non-randomised controlled trial," *Int. Emerg. Nurs.*, vol. 70, p. 101341, 2023.
- [10] Y.-H. Chang *et al.*, "Using machine learning and natural language processing in triage for prediction of clinical disposition in the emergency department," *BMC Emerg. Med.*, vol. 24, no. 1, p. 237, 2024.
- [11] H. Mutegeki, A. Nahabwe, J. Nakatumba-Nabende, and G. Marvin, "Interpretable Machine Learning-Based Triage For

- Decision Support in Emergency Care,” in *2023 7th International Conference on Trends in Electronics and Informatics (ICOEI)*, 2023, pp. 983–990.
- [12] R. Inokuchi, M. Iwagami, Y. Sun, A. Sakamoto, and N. Tamiya, “Machine learning models predicting undertriage in telephone triage,” *Ann. Med.*, vol. 54, no. 1, pp. 2989–2996, 2022.
- [13] İ. Yıldız, “Triage Application with Machine Learning Models.” [Online]. Available: <https://www.kaggle.com/code/ilkeryildiz/triage-application-with-machine-learning-models/data>.
- [14] S. W. Choi, T. Ko, K. J. Hong, and K. H. Kim, “Machine Learning-Based Prediction of Korean Triage and Acuity Scale Level in Emergency Department Patients,” *Healthc. Inform. Res.*, vol. 25, no. 4, pp. 305–312, Oct. 2019.
- [15] A. Kantarci *et al.*, “Machine Learning for E-triage,” *Int. J. Multidiscip. Stud. Innov. Technol.*, vol. 6, Jun. 2022.
- [16] E. Turan, B. Dandıl, and C. Bal, “Grafiksel Arayüz Tabanlı Mermer Sınıflandırma Uygulaması Geliştirme,” *Gazi Üniversitesi Fen Bilim. Derg. Part C Tasarım ve Teknol.*, vol. 8, no. 4, pp. 1034–1050, 2020.
- [17] M. A. Halwani *et al.*, “Predicting triage of pediatric patients in the emergency department using machine learning approach,” *Int. J. Emerg. Med.*, vol. 18, no. 1, p. 51, Mar. 2025.
- [18] E. Alpaydin, *Introduction to machine learning*. MIT Press, 2010.
- [19] Scikit-Learn, “RandomForestClassifier.” [Online]. Available: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>.
- [20] M. Osman, J. He, F. Mokbal, N. Zhu, and S. Qureshi, “ML-LGBM: A Machine Learning Model based on Light Gradient Boosting Machine for the Detection of Version Number Attacks in RPL-Based Networks,” *IEEE Access*, vol. PP, p. 1, Jun. 2021.
- [21] Y. Raita, T. Goto, M. K. Faridi, D. F. M. Brown, C. A. J. Camargo, and K. Hasegawa, “Emergency department triage prediction of clinical outcomes using machine learning models,” *Crit. Care*, vol. 23, no. 1, p. 64, Feb. 2019.
- [22] Z. Gao *et al.*, “Developing and Validating an Emergency Triage Model Using Machine Learning Algorithms with Medical Big Data,” *Risk Manag. Healthc. Policy*, vol. 15, pp. 1545–1551, 2022.
- [23] W. A. Sulaiman *et al.*, “Emergency Department Triage Hospitalization Prediction Based on Machine Learning and Rule Extraction,” in *2023 IEEE EMBS Special Topic Conference on Data Science and Engineering in Healthcare, Medicine and Biology*, 2023, pp. 147–148.
- [24] N. Seesuan, N. Phetkub, A. Rojanasumpong, and N. Chuenjai, *Comparison of the Performance of Machine Learning Models in Predicting ESI Triage Levels Using Data of Non-Traumatic Patients from the Triage Point at the Emergency Medicine Department of Lampang Hospital*. 2024.
- [25] W. S. Hong, A. D. Haimovich, and R. A. Taylor, “Predicting hospital admission at emergency department triage using machine learning,” *PLoS One*, vol. 13, no. 7, p. e0201016, 2018.