

MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE COVID-19 HASTALARININ MORTALİTE RİSKLERİNİN HESAPLANMASI

CALCULATION OF MORTALITY RISKS OF COVID-19 PATIENTS WITH MACHINE LEARNING ALGORITHMS

Mehmet Aziz ÇAKMAK¹
Dr. Öğr. Üyesi Mehmet Emin KURT²
Arş. Gör. Cuma ÇAKMAK³

ÖZ

Bu çalışmanın amacı, Makine Öğrenmesi algoritmalarıyla Covid-19 tanılı hastaların mortalite riskinin hesaplanmasıdır. Bu çalışmada, web üzerinde açık erişimli olarak yayınlanan Atlanta, Georgia'da Covid-19 tanısı alarak sağlık tesisine yatan hastaların demografik ve klinik verileri kullanılmıştır. Bu veriler üzerinden Karar Ağacı, Rastsal Orman ve Adaptive Boost olarak adlandırılan Makine Öğrenmesi algoritmaları kullanılarak hastaların mortalite riski hesaplanmıştır. Hastaların demografik ve klinik bulgularının mortalite riskleri üzerinde etkili olduğu ve bu doğrultuda oluşturulan Makine Öğrenmesi tabanlı tahmin modellemesinin yüksek güvenilirlikle (Acc=83,5) uygulanabileceği görülmüştür. Elde edilen bulgularla birlikte Makine Öğrenmesi yöntemleri kullanılarak yüksek düzeyde güvenilir sınıflandırma modelleri oluşturulup hastaların mortalite risklerinin hesaplanması doğrultusunda klinisyenler ve sağlık profesyonellerine hasta önceliklendirme konusunda kılavuz olabilecek karar destek modülleri oluşturulabilmektedir. Web tabanlı modüller oluşturularak sağlık otoritelerine, klinisyenlere ve hastane yöneticilerine yatak doluluğu planlaması açısından etkin ve verimli hazırlık yapabilmeleri açısından bilimsel dayanak oluşturulmaktadır. Gereksiz sağlık harcamalarının ve hastalığı görece hafif geçirme ihtimali olan hastaların gereksiz tedavi almaları önlenebilecektir.

Anahtar Kelimeler: Makine Öğrenmesi Algoritmaları, Covid-19, Mortalite Riski, Klinik Veriler, Klinisyenler.


JEL Sınıflandırma Kodları: I19, Z00.

ABSTRACT


The aim of the study is to calculate the mortality risk of patients diagnosed with Covid-19 using Machine Learning algorithms. In the study, demographic and clinical data of patients admitted to the health facility with the diagnosis of Covid-19 in Atlanta, Georgia, which are published as open access on the web, are used. The mortality risk of the patients is calculated using Machine Learning algorithms called Decision Tree, Random Forest and Adaptive Boost based on the data. It is observed that the demographic and clinical findings of the patients are effective on mortality risks and that the Machine Learning-based prediction modeling created in this direction can be applied with high reliability (Acc=83.5). With the findings obtained, high-reliability classification models can be created using Machine Learning methods and decision support modules can be created that can guide clinicians and health professionals in patient prioritization in line with the calculation of mortality risks of patients. By creating web-based modules, a scientific basis is established for health authorities, clinicians and hospital managers to make effective and efficient preparations for bed occupancy planning. Unnecessary health expenditures and patients who are likely to have a relatively mild illness can be prevented from receiving unnecessary treatment.

Keywords: Machine Learning Algorithms/Covid-19, Mortality Risk, Clinical Data, Clinicians.

JEL Classification Codes: I19, Z00.

¹  Dicle Üniversitesi, Sosyal Bilimler Enstitüsü, Sağlık Yönetimi Anabilim Dalı, mehmetazizcakmak21@gmail.com

²  Dicle Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Sağlık Yönetimi Bölümü, memin.kurt@dicle.edu.tr

³  Dicle Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Sağlık Yönetimi Bölümü, cuma.cakmak@dicle.edu.tr

EXTENDED SUMMARY

Purpose and Scope:

The aim of this study is to calculate the mortality risk of patients diagnosed with Covid-19 using Machine Learning algorithms. With the findings, it is aimed to help health managers, clinicians, health professionals and health authorities to make effective plans in case of the Covid-19 pandemic and possible future epidemic situations, and to help clinicians make more accurate decisions for their patients who are in the treatment process. The importance and purpose of the research is to help health professionals in the decision to continue their treatment by keeping the patients in the service or intensive care unit according to their clinical course.

Design/methodology/approach:

In this study, demographic and clinical data of patients admitted to the health facility with the diagnosis of Covid-19 in Atlanta, Georgia, which were published as open access on the Web, were used. The mortality risk of the patients was calculated using Machine Learning algorithms called Decision Tree, Random Forest and Adaptive Boost based on this data. In this research, the CRISP-DM methodology, which is frequently used in both industry and technological fields, was used. Special libraries belonging to the Python 3.8 programming language were used in the stages of determining descriptive statistics, creating a model, and measuring the model. The results of the model trained using the training data and test data in our research; Shown on a 2x2 confusion matrix along with True Positive, False Positive, True Negative, False Negative prediction numbers. In this study, the clinical data evaluated within the scope of the studies in the literature are more comprehensive than other studies and by considering certain criteria in the selection of the algorithms used, more effective models have been created and the mortality risks have been tried to be calculated with the help of clinical and demographic data related to Covid-19, and suggestions have been made to health authorities and clinicians.

Findings:

When the data of the patients evaluated within the scope of the study were examined; It was determined that the majority of the sample (37.0%) consisted of Black and Latino (37.2%) individuals. Considering that diseases may cause different prognosis in individuals at the racial level; It is important to evaluate the data of black, Latino, Asian and white individuals in the study.

The mean age of individuals diagnosed with Covid-19 was determined as 63.36 ± 16.70 . When laboratory values were evaluated, it was observed that laboratory values such as DDimer, Platelets, INR, Procalcitonin and Ferritin, which exceeded the reference value ranges, were high, especially in infection patients. It has been observed that the demographic and clinical findings of the patients are effective on mortality risks and that the Machine Learning-based prediction modeling created in this direction can be applied with high reliability (Acc=83.5). In the study, 1414 predictions were made with the test data and the actual values were compared with the predicted values. 1414 estimates; 991 Mortality, 160 vitality correctly estimated (True Positive). 76 estimates were estimated as mortality although there was no mortality. (False Positive). While it should have been estimated as 187 live, it was evaluated as mortality (False Negative). 160 vitality could be estimated correctly. (True Negative).

Conclusion and Discussion:

With the findings obtained, high-reliability classification models can be created using Machine Learning methods and decision support modules can be created that can guide clinicians and health professionals in patient prioritization in line with calculating the mortality risks of patients. By creating web-based modules, a scientific basis is created for health authorities and hospital managers to make effective and efficient preparations for bed occupancy planning. Unnecessary health expenditures and patients who are likely to have a relatively mild illness can be prevented from receiving unnecessary treatment. In the models prepared on the basis of this research, demographic and clinical data of new patients and the risk of death can be calculated with 83.5% confidence. Thus, using the similar modeling method, clinicians can determine the risk of death of new patients and prioritize patients based on scientific basis according to their condition. Decision support outputs as a guide for clinicians or other health professionals can be created through web-based decision support modules to be created through models to be integrated into health informatics at a multidisciplinary level. Considered in terms of health authorities and hospital administrators; Important indicators such as service bed occupancy, intensive care bed planning can be planned more effectively due to the prediction of patients whose condition will worsen.

1. GİRİŞ

2019'un sonlarında, Çin'in Wuhan şehrinde enfeksiyon etkeninin yeni bir koronavirüs türü olduğu anlaşılan ve daha önce de bilim insanları tarafından tespit edilen SARS-CoV virüsü ile benzerliği nedeniyle SARSCoV-2 olarak adlandırılan yeni bir virüs türü ortaya çıkmıştır (Henwood, 2020). Bu epidemiyolojik yayılım daha sonra Dünya Sağlık Örgütü (DSÖ) tarafından ise 11 Mart 2020'de pandemi olarak ilan edilmiştir. 28 Şubat 2022 tarihi itibarıyla küresel boyutta Covid-19 bağlantılı, 434.154.739 resmi vaka, 5.944.342 ölüm vakası Dünya Sağlık Örgütü tarafından bildirilmiştir (WHO, 2022).

Covid-19 enfeksiyonuna yakalanma açısından hastalığı şiddetli bir şekilde geçirme olasılığı en yüksek riskli gruplar; 60 yaş üstü olmak, hipertansiyon, diyabet, kardiyovasküler hastalık, kronik solunum yolu hastalığı ve kanser gibi hastalığa sahip olan kişiler olarak belirtilmiştir (National Health Commission of the PRC., 2021).

Salgına karşı hastaları farklı ve hızlı aşamalarda taramak, virüs yayılımını kontrol altına almak, hastalar ile teması takip edip kontrol altına almak için yeni teknolojik çözümler aranmaktadır. Yapılan araştırmalar sonucunda, Makine Öğrenimi ve Yapay Zekânın, mevcut veriler eşliğinde ileriye yönelik projeksiyonlar oluşturabilme adına daha iyi ölççekler büyüme, hızlandırma işlem gücü, güvenilirlik ve hatta belirli sağlık hizmeti görevlerinde insandan daha iyi performans gösterme gibi yönleriyle, çeşitli sağlık hizmeti sunucuları tarafından kullanılan umut verici teknolojiler olduğu ifade edilmiştir. Makine Öğrenimi ve Yapay Zekâ yöntemleriyle, küresel ölçekte Covid-19 salgınıyla mücadele kapsamında birçok çalışma gerçekleştirilmiştir (Ayaz, 2021).

Covid-19 vakalarının, iyileşenlerinin ve hayatını kaybedenlerin geçmiş verileri kullanılarak, gelecek günler için mevcut parametreler sayesinde devam eden Covid-19 salgının yayılımını önleme ve kontrol altında tutmada tahminlerde bulunulabilir. Yapay zekâ ağırları yöntemi ile sağlanan bu uygulama ile elde edilen sonuçlar değerlendirildiğinde; toplum güvenliğinin sağlanması, daha isabetli politikaların belirlenmesi ve daha doğru kararların alınması gibi konularda hükümetlere ve sağlık otoritelerine yardımcı olacağı düşünülmektedir (Ahmad ve Asad, 2020).

Covid-19 salgınının ne zaman biteceği tahmin edilmeye çalışılmış ve bu sebeple güncel Covid-19 epidemiyolojik veriler kullanarak, makine öğrenmesi tabanlı bir zaman serisi tahmin modeli oluşturulmuştur. Trend eğilimi ile salgının bir pik noktası olacağı varsayımına dayandırılmıştır. Hükümetlerin Covid-19'a karşı almış oldukları ve uyguladıkları tedbirlerin, yapılan tahminleme projeksiyonlarını etkileyebileceği düşünülmektedir. Makine öğrenmesi algoritmalarından elde edilen veriler sayesinde Covid-19 için önerilen tahminleme modelinin etkili olabileceği savunulmaktadır (Wang vd., 2020).

Zheng vd. (2020) tarafından yapılan bir çalışmada; sağlık sistem alt yapısı yetersiz olan ülke veya ülke içi bölgelerde, hastalık riski yüksek olan hastaların hastanelere kabul edilebilmeleri için önceliklendirilmesi gerektiği bunun için de Covid-19 sebebiyle hastane yatış önceliklerinin dört biyolojik belirteç üzerinden ve makine öğrenme algoritmaları yardımıyla yapılması önerilmiştir. Söz konusu çalışma ile pandemilerde klinik ve demografik bulgular ile hastalık sürecinin hızlı ve verimli şekilde tanımlanması, önceliği olan hastanın tedaviye erişiminin sağlanması amacıyla yöneticilere ve klinisyenlere kolaylıklar sağlayacağı gösterilmiştir.

Bu çalışmada klinik ve demografik veriler ile Covid-19 hastalarının mortalite risklerinin hesaplanması amaçlanmıştır. Elde edilen bulgular ile sağlık yöneticileri, klinisyenler, sağlık profesyonelleri ve sağlık otoritelerine Covid-19 pandemisi ve gelecekteki olası salgın durumlarında etkin planlamaların yapılmasına ve klinisyenlere tedavisi sürecinde olan hastalarına yönelik daha isabetli kararlar almalarına yardımcı olunması hedeflenmiştir.

2. LİTERATÜR İNCELEMESİ

2.1. Makine Öğrenmesine Yönelik Teorik Arkaplan

Sağlık bilimleri açısından yenilikçi bir alan olarak sayılabilecek Ortak Karar Verme (OKV) kavramı, hasta bireyler hakkında verilecek tıbbi kararların daha tutarlı olmasını sağlamaya yönelik açıklamalarla tanımlanmaktadır. Pollard vd. (2015) tarafından yapılan bir meta analiz çalışmasında, birden fazla terapötik seçeneğin mevcut olduğu ve sonuçların uzun vadeli ölçülebildiği kronik hastalık yönetimi bağlamında OKV'nin etkisi değerlendirilmiştir. Söz konusu değerlendirme sonucunda hekim rolünün karar vermede etkili olduğu ortaya koyulmuştur.

Klinik Karar Destek Sistemleri (KKDS) ile ilgili olarak yapılan başka bir çalışmada; KKDS ile beraber, iş verimliliği, daha kişiselleştirilmiş bakım sağlama, bakım ve bilgiyi geliştirme, karar vermede güveni artırma, reçete yazma davranışını iyileştirme ve sipariş edilen laboratuvar ve tıbbi görüntüleme testlerinin sayısını azaltma gibi sonuçlar elde edilmiştir (Muhiyaddin vd., 2020).

Hastaların en önemli varlıkları olan yaşamları hakkında karar verme noktasında klinisyenlerin ve diğer sağlık profesyonellerin yeri önemlidir. Bu bağlamda tıbbi kararlar çerçevesinde hassasiyet gösterilmesiyle olumlu sağlık çıktıları oluşabilmekteyken, bu düzeyde yapılacak ufak hatalar ise geri dönüşü zor zararlara neden olabilmektedir. Klinisyenler ile makine öğrenmesi algoritmalarıyla oluşturulmuş derin öğrenme ağlarının tahmin sonuçları karşılaştırıldığında, birçok alanda klinisyenlerin doğru tanı sayıları algoritmalarla yapılan doğru tahmin sayılarından daha az olmaktadır (Şahin, 2018). Klinik karar verme aşamasında insan hatasını en aza indirmek amacıyla makine öğrenmesi algoritmalarıyla oluşturulmuş karar destek sistemleri kayda değer sonuçlar oluşturabilmektedir.

OKV konseptine Klinik Karar Destek Sistemleri entegre edilerek, temel amaç olan hasta bireyler hakkındaki en doğru tıbbi karara ulaşma hedefine daha hızlı ulaşılabileceği düşünülmektedir. Bu çalışmada Covid-19 tanılı hastaların sayısının arttığı dönemlerde, sağlık sistemleri üzerindeki baskının arttığı, sağlık tesislerine yatarak tedavi edilmesi gereken Covid-19 tanılı hastaların mevcut yatak doluluğundan dolayı takip ve tedavi açısından seçilmesi gereken durumlarda klinisyenler ve sağlık profesyonellerine bilimsel temeller üzerine kurulu tahmin sonuçlarını oluşturmak, tıbbi karar mekanizmasına destek sağlamak amaçlanmıştır.

2.2. Sağlık Hizmetlerinde Makine Öğrenmesi ve Önemi

Yapay zekâ ve makine öğreniminin ticari uygulamaları, özellikle görüntü tanıma, doğal dil işleme, dil çevirisi, metin analizi ve kendi kendine öğrenme gibi alanlarda son zamanlarda kayda değer ilerleme kaydetmiştir (Connor, 2019). Hem gelişmiş teknikler hem de olağanüstü hacme sahip veri tabanları ile beraber günümüzde karmaşık veri analizini çeşitli endüstrilere uygulamaya odaklanan şirketlerin sayısı hızla artmış ve bu sebeple bazı analitik şirketler, dikkatlerini sağlık hizmetlerindeki sorunlara çevirmiştir.

Literatür incelendiğinde; tıbbi verilere makine öğrenimi algoritmalarını uygulayan çok sayıda çalışma olmasına rağmen, bunların çok azının klinik bakım özelinde sağlık hizmetlerine anlamlı bir şekilde katkıda bulunduğu tespit edilmektedir. (Deo, 2015). Görece az sayılabilecek çalışmalar dahi anlamlı katkılar sunarak değerli sonuçlar gösterebilmektedir. Özellikle sağlık hizmetleri kapsamında ortaya çıkan tıbbi kayıtlar ve verilerle yapılan tahmin çalışmalarına odaklanmak, maliyeti nispeten daha düşük ve uygulanabilirliği yüksek modeller geliştirmek adına önem arz etmektedir.

Tahmine dayalı analitik alanının, hastalıkları teşhis etme ve tedavi etme şeklini ve biyomedikal bilim araştırmalarının yürütülmesini temelden değiştirmesi beklenmektedir. (Saber vd., 2019). Makine öğrenmesi algoritmalarının sağlık hizmetlerine uygulandığı alanlar sağlık problemlerinin tahminlerinin yapılabilmesi odağında şekillenmiştir. Bu düşünce söz konusu tahmin uygulamalarına derin bir bakış açısıyla yaklaşmayı gerektirmekte ve alanla ilgili olarak örnek çalışmaları aktarmayı değerli kılmaktadır.

Küresel boyutta gittikçe daha da önemli bir konu haline gelen ve sağlık hizmetleri açısından önemli problemler olarak sayılabilen, beslenme ile ilgili sağlık problemleri (yetersiz beslenme, obezite vs.), kalp ve damar hastalıkları gibi hastalıklara yönelik tahmin çalışmaları yapılarak söz konusu problemlere çözümler aranmıştır. Bu çalışma alanlarında elde edilen sonuçlar incelenerek söz konusu durumun önemi hakkında fikirler edinilebilmektedir.

- Sensörlerden, akıllı telefon uygulamalarından, elektronik tıbbi sağlık kayıtlarından ve sigorta verilerinden elde edilen obezite ile ilgili zengin veri kaynakları, obeziteyi anlamak, önlemek ve tedavi etmek için yeni anlayışlar getirebilir. Bu tür büyük veri kümeleri için makine öğrenimi, obezite ile ilgili riskleri ve sonuçları tanımlamak, sınıflandırmak ve tahmin etmek için gelişmiş ve oldukça hassas araçlar sağlamaktadır (DeGregory vd., 2018).
- Oh vd. (2019)'nin özelleştirilmiş derin sinir ağı ve makine öğrenimi sınıflandırıcıları, NHANES (Ulusal Sağlık ve Beslenme Sınavı Anketi) veri tabanından (1999'dan 2014'e kadar) 19.725 katılımcının ve 2014'te Güney Kore NHANES (K-NHANES) veri tabanından 4949 katılımcının anket verileri kullanılarak gerçekleştirdikleri çalışmada; Derin sinir ağları hem NHANES hem de K-NHANES veri kümelerinde diğer sağlık ve demografik faktörler arasından depresyonu çok iyi bir şekilde tanımlamayı başarmıştır.

- Akıllı saat kullanıcıları tarafından kolaylıkla ölçülebilen sağlıkla ilgili verileri kullanarak kardiyovasküler hastalık prevalansını tahmin eden bir model geliştirmeyi amaçlamış ve destek vektör algoritmalarıyla yüksek güvenilirlikli tahmin modeli oluşturulmuştur (Kim, 2021).
- Alaa vd. (2019) tarafından yapılan bir çalışmada; UK Biobank'ta başlangıçta Kardiyovasküler Hastalık (KVH)'ı olmayan 423.604 katılımcıya ilişkin verileri kullanarak, 473 mevcut değişkene dayalı olarak KVH riskini tahmin etmek için makine öğrenmesi tabanlı bir model geliştirilmiştir ve kardiyovasküler hastalık riski hakkında kayda değer tahmin sonuçları elde etmiştir.

Tahmine dayalı analitiklerin doğruluğu ve kesinliği son birkaç yılda önemli ölçüde artmış ve bu göstergeler üstel bir hızla gelişmektedir. Bu sebeple tahmin algoritmalarının sağlık hizmetleri gibi hassas bir alana uygulanabilirliği kolaylaşmaktadır. Makine öğrenmesi konseptinin sağlık hizmetleri alanına uygulanması ile ilgili olarak yapılan çalışmalar gün geçtikçe artmakta dolayısıyla araştırmacıların dikkatleri bu alana yoğunlaşmaktadır. Bu bağlamda makine öğrenmesi metotları ile yapılan çalışmalar ile sağlık hizmetlerini kolaylaştırmaya yönelik araştırmalar giderek artmaktadır.

Covid-19 pandemisi ile ilgili olarak Seroloji ve RT-PCR gibi geleneksel yöntemlerin yanı sıra CRISPR/Cas ve yapay zeka/makine öğrenimi gibi en son teknolojilerin nasıl olduğu konusunda multidisipliner bir bakış açısının sunulduğu çalışmalar mevcuttur (Sreepadmanabh vd., 2020).

Li vd. (2020) 151 yayınlanmış çalışmadan Covid-19 verilerini yeniden analiz etmek için makine öğrenimi uygulayarak hasta semptomlarına ve rutin test sonuçlarına dayalı olarak daha doğru bir Covid-19 tanı modeli oluşturmuş; Büyük klinik veri kümeleri üzerinde eğitilen hesaplama yöntemlerinin, test eksikliğinin etkisini azaltmak için her zamankinden daha doğru Covid-19 teşhis modelleri sağlayabileceğini gösterilmiştir. Ayrıca daha önce bilinmeyen Covid-19 klinik değişken korelasyonlarını ve klinik alt grupları sunulmuştur.

Hazır klinik ve laboratuvar verilerini kullanarak Covid-19 teşhisi ve ölüm riski ve ciddiyetinin tahmini ile ilgili olarak kullanılan makine öğrenmesi algoritmalarının büyük kısmı denetimli öğrenme algoritmalarıdır ve ilgili araştırmaların çoğu deneyseldir. Makine Öğrenmesi (ML/MÖ) modelleri tarafından keşfedilen tanısal ve prognostik özellikler, tıbbi literatürde sunulan sonuçlarla uyumludur (Alballa ve Al-Turaiki,2021).

Moulaei vd. (2022) tarafından 1500 hasta ile yapılan mortalite tahmin çalışmasında; 38 değişkenden dispne, yoğun bakıma yatış ve oksijen tedavisi ilk üç belirleyici olarak bulunmuştur. Sigara, alanin aminotransferaz ve trombosit sayısının Covid-19 mortalitesinin en düşük üç belirleyicisi olduğu bulunmuştur. Deneysel sonuçlar, rastgele ormanların (RF) sırasıyla %95.03, %90.70, %94.23, %95.10 ve %99.02 doğruluk, duyarlılık, kesinlik, özgüllük ve alıcı çalışma karakteristiği (ROC) ile diğer ML algoritmalarından daha iyi performansa sahip olduğunu göstermiştir.

2.3. İlgili Çalışmalar

Çalışma kapsamında değerlendirilen Covid-19 tanıli hastaların mortalite ve morbidite risklerinin hesaplanmasında benzer yöntemlerin kullanıldığı çalışmalar incelenmiştir. Söz konusu duruma modelleme açısından benzer sayılabilecek çalışmaların mevcut olduğu görülmüştür. Yenidoğan Yoğun Bakım Ünitesinde yatmakta olan hastaların hastalık durumlarından, karaciğer yağlanması ile ilgili olarak tahminlerin yapıldığı araştırmalara kadar farklı alanlarda yapılmış çalışmaların mevcut olduğu görülmektedir. Bu doğrultuda ilgili sayılabilecek çalışmalar ve detayları şu şekilde sıralanmıştır;

- Helsinki Üniversite Hastanesi Çocuk Hastanesinin yenidoğan yoğun bakım ünitesinde toplanan zaman serisi verileri ve klinik değişkenlerle 9 farklı sınıflandırıcı incelenmiş ve en iyi sınıflandırıcının AUROC (Area Under the Receiver Operating Characteristics- Alıcı Çalışma Özellikleri Altındaki Alan) değerleri; mortalite tahmininde 0.922, bronkopulmoner displazi tahmininde 0.899, nekrotizan enterokolit tahmininde 0.806, prematüre retinopatisinin tahmininde 0.846 ve ölüm tahmininde 0,493 olarak tespit edilmiştir (Jaskari vd., 2020)
- Matsuo vd. (2020) tarafından yapılan bir diğer çalışmada, Travmatik Beyin Yaralanması (TBY) ile ilgili olarak tahmin gerçekleştiren basit bir Makine Öğrenmesi modeli geliştirmek adına; sırt (ridge) regresyonu, en az mutlak küçülme ve seçim operatörü (LASSO) regresyonu, rastgele orman, gradyan artırma, ekstra ağaçlar, karar ağacı, Gauss saf Bayes, çok terimli saf Bayes ve destek vektör makinesi olmak üzere 9 algoritmanın performans karşılaştırması yapılmıştır. Söz konusu araştırma bulgularına göre; Rastgele orman algoritmasının en kötü performansı gösterdiği, en iyi performansı ise sırt regresyonu analizinin gösterdiği belirtilmiştir. Ağaç

tabanlı topluluk algoritmasını kullanan özellik seçme yöntemine dayalı olarak, yaş, Glasgow Koma Ölçeği, fibrin/fibrinojen bozunma ürünleri ve glukoz değişkenleri mortalite için en önemli prognostik (tanısal) faktörler olarak tanımlanmıştır.

- Kılıç vd. (2021) tarafından yapılan çalışmada; 2007 ve 2017 yılları arasında The Society of Thoracic Surgeons (STS) Ulusal Veritabanında elde edilen 243.142 izole Kalp Kapağı Değişim Ameliyatı (SAVR) uygulanan yetişkin hastalarla ilgili olarak aşırı gradyan artırma (XGBoost) makine öğrenmesi algoritması kullanılarak operasyon ile ilgili göstergeler tahmin edilmiştir. Söz konusu çalışmada, XGBoost algoritmasıyla 0,985'lik bir doğruluk düzeyinde tahminler yapılabilmektedir (Kılıç vd., 2021).
- Wu vd. (2019) tarafından karaciğer yağlanmasıyla ilgili 577 hastaya ait bilgiler kullanılarak makine öğrenmesi modeli uygulanan araştırma sonuçlarına göre; Rastgele Orman (RF), Naive Bayes (NB), Yapay Sinir Ağları (ANN) ve Lojistik Regresyon (LR) algoritmalarının denendiği modellemede sırasıyla 87.48%, 82.65%, 81.85% ve 76.96% doğruluk düzeyleri elde edilmiştir. Rastgele orman modeli diğer sınıflandırma modellerinden daha yüksek performans göstermiştir.

3. YÖNTEM

3.1. Araştırmanın Amacı ve Önemi

Bu araştırma kapsamında makine öğrenmesi algoritmalarıyla tahmin edilen mortalite riskleri ile ilgili olarak literatür taraması yapılmıştır. Covid-19 pandemisinin görece yeni olması, alanla ilgili yapılan çalışmaların nispeten diğer konulara göre daha sınırlı sayıda olması öncelikle bu çalışmanın önemli yanını ortaya koymaktadır. Covid-19 tanılı hastalara ait demografik ve klinik veriler kullanılarak makine öğrenmesi algoritmalarıyla mortalite riski hesaplanan çalışmalar mevcut olmakla beraber; kullanılan klinik verilerin sayısı, kullanılan algoritmaların çeşitliliği ve uygun algoritma seçiminde ortaya çıkan yanlılık çalışmaları birbirinden farklılaştırmaktadır. Bu çalışmada, literatürde yapılan çalışmalar kapsamında değerlendirilen klinik verilerin diğer çalışmalardan daha kapsamlı olması ve kullanılan algoritmaların seçiminde belirli kriterlerin göz önünde bulundurulmasıyla daha etkili modeller oluşturularak Covid-19 ile ilişkili klinik ve demografik veriler yardımıyla mortalite riskleri hesaplanmaya çalışılmış sağlık otoriteleri, klinisyenlere önerilerde bulunulmaya çalışılmıştır.

3.2. Etik Onay

Araştırmada kullanılan veriler internet üzerinden açık erişimlidir. Herkes bu verilere söz konusu internet sayfası üzerinden erişim sağlayabilmektedir. Çalışmada hastalar üzerinde gerçekleştirilen klinik bir çalışma değildir. Söz konusu gerekçelerden ötürü Etik Kurul Belgesine ihtiyaç olmadığı düşünülmektedir.

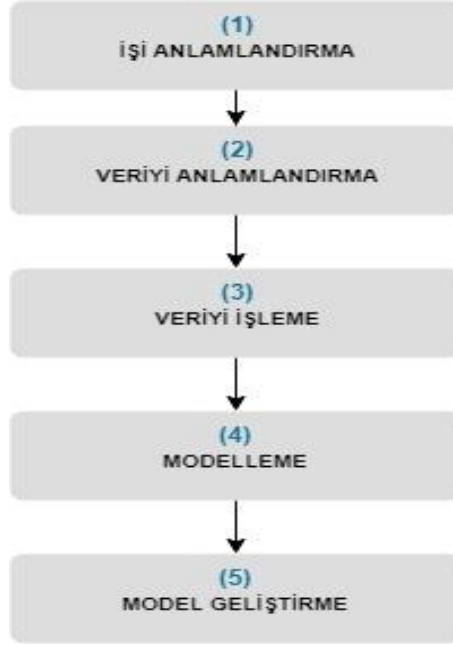
3.3. Veri Seti

Bu çalışma kapsamında Atlanta, Georgia'da sağlık hizmeti sunumu yapan bir sağlık tesisinde Covid-19 tanısıyla tedavi görmüş hastaların demografik özellikleri ve laboratuvar bulgularının tutulduğu, web tabanlı bir sistem üzerinden açık erişimli olarak paylaşılan bir veri seti kullanılmıştır (Altschul vd., 2021). Veri seti ile ilgili değişkenler incelenmiş ve çalışmada kullanılacak değişkenlerle yeni bir veri seti oluşturulmuştur. Oluşturulan veri setinde orijinal verilere ait bir kayıp yaşanmamasına dikkat edilmiştir. Veriler SpringerNature açık erişimli web sayfasından alınmıştır.

Bu çalışmada hem endüstride hem de teknolojik alanlarda sıklıkla kullanılan CRISP-DM metodolojisi kullanılmıştır. CRIP-DM metodolojinin büyük veri madenciliği projelerinde etkin, az maliyetli, tekrarlanabilir ve güvenilir olması çalışmada kullanımının uygun olduğunu göstermektedir (Wirth ve Hipp, 2000). Araştırmada kullanılan metodolojik yaklaşım Şekil 1'de gösterilmektedir.

İyi tahmin yapan ve hesaplama açısından verimli olan Karar Ağaçları araştırmacılar tarafından sıklıkla kullanılan ve popülerliğini koruyan sınıflandırma teknikleridir (Breiman vd., 2017). Bu sebeple çalışmada bu yöntemle geliştirilen modeller kullanılmıştır. Modelleme ve oluşturulan modellemenin ölçülmesi aşamalarında makine öğrenmesi ait Decisions Tree, Rainforest, AdaBoost algoritmaları kullanılmıştır. Tanımlayıcı istatistikleri belirleme, model oluşturma, modelin ölçülmesi aşamalarında Python 3.8 programlama diline ait özel kütüphaneler kullanılmıştır.

Şekil 1. Çalışma Akış Diagramı



Kaynak: Bu görsel yazarlar tarafından oluşturulmuştur.

3.4. İş Anlamlandırma

Araştırmada Covid-19 tanılı hastaların genel profili çıkarılmış ve bu hastalara ait veriler arasında anlamlı çıkarımlar yapılmaya çalışılarak araştırmanın temel amacı belirlenmiştir. Oluşturulan modelleme sonucunda elde edilen parametrik değerlerden yola çıkarak hastaların özellikle mortalite ihtimalleri hesaplanmaya çalışılmıştır. Covid-19 hastalığı bir süreç olarak değerlendirildiğinde hastaların klinik seyirlerinin günden güne değiştiği bilinmektedir. Sağlık sunumu açısından hastalara durumlarının şiddeti paralelinde tedavi verilmesi klinik seyir açısından önemlidir. Hastalığın en temel karakteristiğinin akciğer tutulumuna bağlı nefes darlığı, hava açlığı, nefes almakta zorlanma, kanın yeterince oksijenlenememesi gibi ciddi durumlar olması sebebiyle doğru hastaya doğru zamanda doğru şekilde tedavi verilmesi hayat kurtarıcı olmaktadır (Zhang vd., 2019). Hastaların klinik seyirlerine göre servis veya yoğun bakım ünitesinde tutularak tedavisine devam edilmesi kararında sağlık profesyonellerine yardımcı olmak araştırmanın önemini ve amacını oluşturmaktadır.

3.5. Veriyi Anlamak

Veriyi anlamak, değişkenleri karşılaştırabilmek, verinin hangi amaçlara uygun olabileceğini anlayabilmek gibi önemli teknik durumlar çalışmanın metodolojisinde önemli bir yer tutmaktadır. Araştırmada kullanılan veri setine ait değişkenler incelenmiş ve tanımlayıcı istatistikler yardımıyla değişkenler arasındaki ilişki anlamlandırılmıştır.

3.6. Veri Önileme

Araştırmada kullanılan veri seti, uygun makine öğrenmesi modellenmesi algoritmalarıyla kullanılmak üzere hazır hale getirilmiştir. Bu hazırlık evresinde; gözlemler incelenerek eksik verilerin olup olmadığı kontrol edilmiştir. Tüm değişkenlere ait veriler incelendiğinde eksik veri olmadığı anlaşılmıştır.

Veri setindeki değişkenler karşılaştırılarak verilerin gerçeğe uygun olup olmadığı ölçülmüştür. Literatürdeki vital değer aralıkları ile çalışmada kullanılan veriler karşılaştırılmıştır (Sapra vd., 2021). Veri setinde rastgele gözlemler alınarak vital bulgular ile etiket parametre (yaşayan=1, yaşamayan=0) ile karşılaştırma yapılmıştır. Veri seti incelendiğinde hem kategorik verilerin hem de numerik verilerin olduğu gözlemlenmiştir. Hatta bir değişkene ait referans değerleri arasında olup-olmama durumu bile kategorik veri olarak sunulmuştur. Temel verilere dayanarak oluşturulan bu kategorik değişkenler verinin gerçekliğe uygunluğu ölçmek için kullanılmış olup durumun uygunluğu doğrulanmıştır. Veri setinde kullanılan tüm değişkenler ve tanımları Tablo 1'de ayrıntılı olarak gösterilmiştir.

Tablo 1. Değişkenler ve Tanımları

Sıra	Değişken Adı	Tanım
1	LOS_Y	Hastanede Yatış Durumu (Evet/Hayır)
2	LOS	Hastanede kalış süresi
3	Death	Ölüm (Evet/Hayır)
4	Black	Siyahi Irk
5	White	Beyaz Irk
6	Asian	Asya Irkı
7	Latino	Latin Irk
8	MI	Geçirilmiş Kalp Krizi (Evet/Hayır)
9	PVD	Periferik Damar Hastalığı (Evet/Hayır)
10	CHF	Konjetif Kalp Hastalığı (Evet/Hayır)
11	CVD	Kardiyovasküler Hastalık (Evet/Hayır)
12	DEMENT	Demans (Evet/Hayır)
13	COPD	KOAH (Evet/Hayır)
14	DM Complicated	Diyabet Tip 2 (Evet/Hayır)
15	DM Simple	Diyabet Tip 1 (Evet/Hayır)
16	Renal Disease	Böbrek Hastalığı (Evet/Hayır)
17	All CNS	All CNS
18	Pure CNS	Pure CNS
19	Stroke	İnme (Evet/Hayır)
20	Seizure	Nöbet Geçirme (Evet/Hayır)
21	OldSyncope	Bayılma Geçmişi (Evet/Hayır)
22	OldOtherNeuro	Geçirilmiş Nörolojik Hastalık (Evet/Hayır)
23	OtherBrnLsn	Geçirilmiş Beyin Hasarı (Evet/Hayır)
24	Age	Yaş
25	AgeScore	Skorlanmış Yaş
26	O2SatsYes	Oksijen Satürasyonu (Evet/Hayır)
27	OsSats	Oksijen Saturasyon (%)
28	O2 Sat < 94	Oksijen Saturasyonu < %94 (E/H)
29	TempYes	Ateş (Evet/Hayır)
30	Temp	Ateş (Sayısal Değer Olarak)
31	Temp > 38	Ateş >38 santigrat (Evet/Hayır)
32	MapYes	Ortalama Arterial Tansiyon (Evet/Hayır)
33	MAP	Ortalama Arterial Tansiyon Değeri (mmHg)
34	MAP < 70	Ortalama Arterial Tansiyon < 70 mmHg (Evet/Hayır)
35	DDimerYes	D-dimer (Evet/Hayır)
36	Ddimer	D-dimer değeri (mg/ml)
37	D-Dimer > 3	D-dimer değeri, mg/ml > 3 (Evet/Hayır)
38	PltsYes	Platelets (Evet/Hayır)
39	Plts	Platelets değeri (mm ³)
40	PltsScore	Platelets Skoru (kategorik)
41	INRYes	INR (Evet/Hayır)
42	INR	INR değeri

Sıra	Değişken Adı	Tanım
43	INR > 1.2	INR değeri > 1.2 (Evet/Hayır)
44	BUNYes	Kan Nitrojenize Üre (Evet/Hayır)
45	BUN	Kan Nitrojenize Üre Değeri(mg/dL)
46	BUN > 30	Kan Nitrojenize Üre Değeri > 30 (Evet/Hayır)
47	CrtnYes	Kreatin Değeri (Evet/Hayır)
48	Creatinine	Kreatin Değeri
49	CrtnScore	Kreatin Skoru (Evet/Hayır)
50	SodimuYes	Sodyum (Evet/Hayır)
51	Sodium	Sodyum Değeri
52	Sodium < 139 or > 154	< 139 Sodyum > 154 (Evet/Hayır)
53	GlucoseYese	Kan Şekeri (Evet/Hayır)
54	Glucose	Kan Şekeri Değeri
55	Glucose <60 or > 500	<60 Kan Şekeri Değeri > 500 (Evet/Hayır)
56	ASTYes	AST (Evet/Hayır)
57	AST	AST Değeri (U/litre)
58	AST > 40	AST Değeri (U/litre) > 40 (Evet/Hayır)
59	ALTYes	ALT (Evet/Hayır)
60	ALT	ALT Değeri
61	ALT > 40	ALT Değeri > 40
62	WBCYes	Beyaz Kan Hücresi (Evet/Hayır)
63	WBC	Beyaz Kan Hücresi Sayısı(mm3)
64	WBC <1.8 or > 4.8	<1.8 Beyaz Kan Hücresi Sayısı > 4.8 (Evet/Hayır)
65	LymphoYes	Lenfosit (Evet/Hayır)
67	Lympho	Lenfosit Değeri
68	Lymphocytes < 1	Lenfosit Değeri < 1 (Evet/Hayır)
69	IL6Yes	IL-6 (Evet/Hayır)
70	IL6	IL-6 Değeri (pg/ml)
71	IL6 > 150	IL-6 Değeri > 150 (Evet/Hayır)
72	FerritinYes	Ferritin (Evet/Hayır)
73	Ferritin	Ferritin Değeri
74	Ferritin > 300	Ferritin Değeri > 300 (Evet/Hayır)
75	CrctProtYes	C-Reaktif Protein (Evet/Hayır)
76	CrctProtein	C-Reaktif Protein Değeri
77	C-ReactiveProt > 10	C-Reaktif Protein Değeri > 10 (Evet/Hayır)
78	ProCalCYes	Prokalsitonin (Evet/Hayır)
79	Procalcitonin	Prokalsitonin Değeri
80	Procalciton > 0.1	Prokalsitonin Değeri > 0.1 (Evet/Hayır)
81	TropYes	Troponin (Evet/Hayır)
82	Troponin	Troponin Değeri
83	Troponin > 0.1	Troponin Değeri > 0.1 (Evet/Hayır)

Araştırma kapsamında veri setine ait değişkenler incelenmiş ve makine öğrenmesi algoritmalarında kullanılacak değişkenler seçilmiştir. Bu seçim sonucunda değerlendirilen bilgiler Tablo 2’de ayrıntılı olarak gösterilmiştir.

Tablo 2. Kullanılan Veri Setine Ait Bilgiler

Tablo Adı	Toplam Satır	Toplam Sütun
Orijinal Veri Seti	4711	83
Yeni Veri Seti	4711	41
Yeni Veri Setinde Kullanılan Değişkenler	'Black', 'White', 'Asian', 'Latino', 'MI', 'PVD', 'CHF', 'CVD', 'DEMENT', 'COPD', 'DM Complicated', 'DM Simple', 'Renal Disease', 'All CNS', 'Pure CNS', 'Stroke', 'Seizure', 'OldSyncope', 'OldOtherNeuro', 'OtherBrnLsn', 'Age', 'OsSats', 'Temp', 'MAP', 'Ddimer', 'Plts', 'INR', 'BUN', 'Creatinine', 'Sodium', 'Glucose', 'AST', 'ALT', 'WBC', 'Lympho', 'IL6', 'Ferritin', 'CrctProtein', 'Procalcitonin', 'Troponin'	

3.7. Modelleme

Araştırmada kullanılan veri seti, oluşturulan makine öğrenmesi algoritmalarının öğrenme işleminin gerçekleştirilmesi ve bu öğrenme işlemi sonunda anlamlı tahminler oluşturabilmesi için %70 eğitim ve %30 test verisi olarak iki ayrı alt veri setine ayrılmıştır.

Araştırma modellemede aşağıdaki adımlar takip edilmiştir;

- Veri setini eğitim ve test verilerine ayır,
- Eğitim verileri üzerinden değişkenlerin birbirleriyle olan gizli örüntülerini öğren,
- Öğrenilen durum üzerinden mortalite riskini tahmin et,
- Tahmin verileri ve test verilerini karşılaştır,
- Karşılaştırılan veriler doğrultusunda güvenilirlik oranını hesapla,

3.7.1. Karar Ağacı

Karar Ağacı veri madenciliği, makine öğrenmesi gibi modellemelerde sıklıkla kullanılan bir sınıflandırma yöntemidir. Bilimsel keşif, bankacılık uygulamaları, satış tahminleme, pazarlama gibi alanlarda kullanılan önemli bir yöntemdir (Brijain vd., 2014).

Tıbbi alanlarda doğru gözlenen verilere dayanarak doğru kararlar almak diğer disiplinlere göre daha önemlidir. Karar ağaçları tıbbi alanda kullanılabilirliği yüksek, geliştirilen modelin etkinliğine göre yüksek sınıflandırma doğruluğu sağlayan, güvenilirliği yüksek bir yöntemdir. Bu yönüyle karar ağacı tıbbi karar vermede kullanılmıştır (Vens vd., 2008).

Veri seti üzerinden yapılan karar ağacı tahmin sonuçlarına göre Entropy ve Gini İndex kriterlerinin güvenilirlik sonucu yüksek olan Entropy (Accuracy: %81,4) değerinin kullanılması uygun görülmüştür. Gini İndex (Accuracy: %81,2) elenmiştir. Entropy ve Gini İndex ayrı ayrı denenerek Tablo 3'te gösterilen güvenilirlik sonuçları elde edilmiştir.

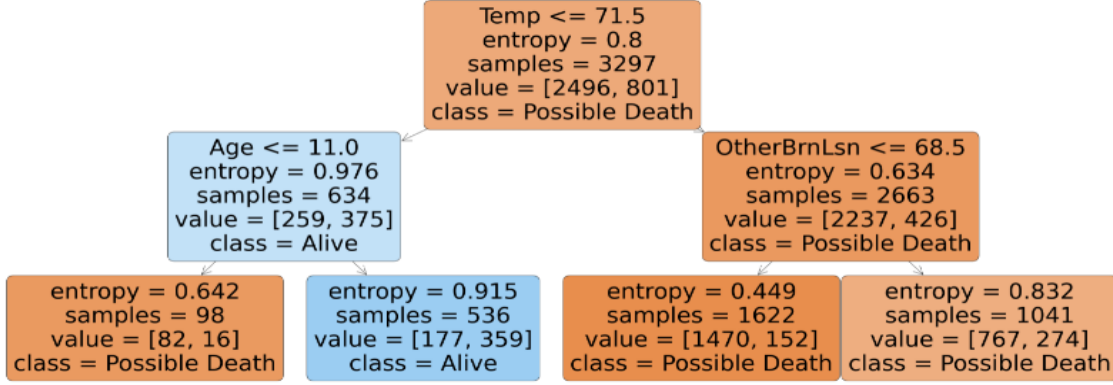
Tablo 3. Karar Ağacı Kriter Değerlendirmesi

ALGORİTMA	KRİTER	GÜVENİRLİK
Karar Ağacı	Entropy	81,4
	Gini İndex	81,2

Kaynak: Çalışmamızda yapılan hesaplamalar sonucunda oluşturulmuş tablodur.

Araştırmada modellenen karar ağacında kullanılan değişken sayısı görece fazla olduğundan sistem çıktısı olarak dönen karar ağacı grafiğinin sadece 3.dallanma seviyesine kadar gösterimi Şekil 2'de gösterilmiştir. Modellenen karar ağacında bilgi kazanımı (gain information) en yüksek değer ateş (gain <= 71.5) değeri olduğundan bu değer kök (root) olarak tutulmuş, yaş (gain <= 11.0) ve diğer beyin hasarı değeri (gain <= 68.5) 2.dallanma olarak tutulmuştur. Bilgi kazanımı kriterine göre diğer seviyelerde dallanmalar oluşturulmuştur. Bu çalışma sonucunda elde edilen karar ağacına ait ilk üç düğüm (dallanma) gösterilmiştir.

Şekil 2. Karar Ağacı Sonuç Diagramı



Kaynak: Bu görsel yazarlar tarafından oluşturulmuştur

3.7.2. Rastal Orman Algoritması

Rastal Ormanlar ya da başka bir deyişle rastsal karar ağaçları, modelleme aşamasında birden fazla karar ağacı oluşturarak optimal sınıflandırma yapan bir makine öğrenmesi yöntemidir. Bu çalışmada karar ağaçlarıyla elde edilen güvenilirlik oranından daha yüksek bir oran elde edilebilmesi için rastsal karar ağacı yöntemi uygulanmıştır. Tahminleyici kriter (estimator) durumuna göre güvenilirlik oranı hesaplanmış ve optimal kriter seçilmiştir. Modelin aşırı öğrenme veya eksik öğrenme durumunu engellenmeye çalışılmıştır. Sonuçlar tablo 4'te gösterilmiştir.

Tablo 4. Rastsal Orman Metoduyla Elde Edilen Güvenirlik Oranı Tablosu

ALGORİTMA	ESTİMATÖR	GÜVENİRLİK (%)
Rastal Orman Algoritması	10	80,9
	20	83,3
	30	82,1
	40	83,5
	50	83,4
	60	83,4
	70	83,1
	80	82,9
	90	83,0
	100	83,0

3.7.3. AdaBoost Algoritması

Diğer öğrenme algoritmalarının zayıf öğrenme çıktılarını güçlendirmek ve daha yüksek güvenilirlik oranları elde etmekte kullanılan Adaptive Boosting (AdaBoost) algoritmaları önemli bir öğrenme meta-algoritmasıdır. Bu çalışmada elde edilen öğrenme çıktılarının geliştirilmesi ve daha yüksek güvenilirlik oranına sahip tahminleme sağlanmaya çalışılmıştır. AdaBoost algoritmalarıyla sonuca yönelik optimizasyon durumu araştırılmış ve elde edilen bulgular tablo 5'te gösterilmiştir.

Tablo 5. AdaBoost Güvenirlilik Oranı

ALGORITMA	ESTİMATÖR	GÜVENİRLİK (%)
ADABOOST	10	81,4
	20	82,1
	30	81,9
	40	83,0
	50	83,2
	60	82,8
	70	82,8
	80	83,3
	90	83,0
	100	82,8

3.8. Model Geliştirme

Herhangi bir çalışma kapsamında oluşturulan modeller kullanılan gözlemlere karşı değerlendirilir ve modeller arasındaki farklılıklar bir dizi karşılaştırma yöntemleriyle elde edilen bilgiler araştırılır (McAvaney vd., 2001). Araştırma kapsamında elde edilen modelin etkinliğinin değerlendirilmiş ve sonuçların kayda değer olup olmadığı araştırılmıştır.

3.8.1. Güvenirlilik Hesaplaması (Accuracy Calculation)

Doğru Pozitif (DP): Gerçek pozitif, doğru tahmin edilen pozitif değerler (Araştırmamızdaki kullanımı: gerçek mortalite tahminleri)

Yanlış Pozitif (YP): Yanlış pozitif, doğru tahmin edilemeyen değerler (Araştırmamızdaki kullanımı: yanlış mortalite tahminleri)

Doğru Negatif (DN): Gerçek negatif, doğru tahmin edilen negatif değerler. (Araştırmamızdaki kullanımı: doğru canlılık tahminleri)

Yanlış Negatif (YN): Yanlış negatif, yanlış tahmin edilen negatif değerler. (Araştırmamızdaki kullanımı: yanlış canlılık tahminleri)

Doğruluk/Güvenirlilik: Bir testin doğruluğu, hastalıklı ve sağlıklı vakaların doğru bir şekilde ayırt edebilmesiyle ölçülebilmektedir. Güvenirliliği tahmin etmek için, değerlendirilen tüm vakalarda gerçek pozitif ve gerçek negatif oranı hesaplanmalıdır. Matematiksel olarak şu şekilde ifade edilebilir;

$$\text{Güvenirlilik} = \frac{DP+DN}{DP+DN+YP+YN} \quad (1)$$

Duyarlılık: Bir testin duyarlılığı, hasta vakaların doğru bir şekilde belirleme yeteneğidir. Bunu tahmin etmek için, hasta vakalardaki gerçek pozitif oranı hesaplanmalıdır. Matematiksel olarak şu şekilde ifade edilebilir;

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (2)$$

Özgüllük: Bir testin özgüllüğü, sağlıklı vakaları doğru bir şekilde belirleyebilmesidir. Bu değeri tahmin edebilmek için sağlıklı vakalarda gerçek negatif oranı hesaplanmalıdır. Matematiksel olarak şu şekilde ifade edilebilir;

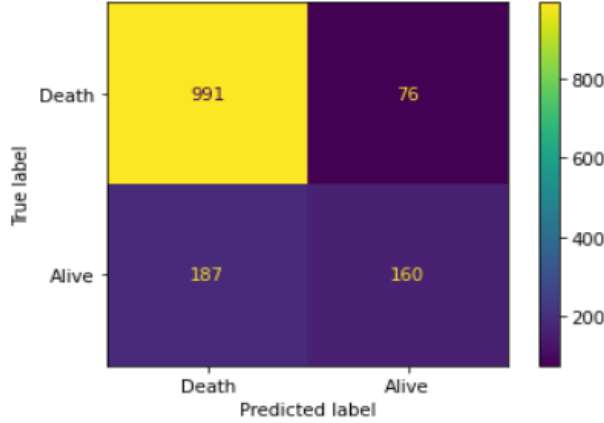
$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (3)$$

3.8.2. Karmaşıklık Matrisi

Karmaşıklık Matrisi gerçek değer ile tahmin edilen değerleri n X n matris halinde göstererek modelin güvenirlilik oranını gözle görülebilir bir hale getirmektedir (Visa vd., 2011).

Araştırmamızda eğitim verileri ve test verileri kullanılarak eğitilen model sonuçları; Doğru Pozitif, Yanlış Pozitif, Doğru Negatif, Yanlış Negatif sayılarıyla beraber 2x2'lik bir confusion matrisi üzerinden gösterilmiştir. Bu araştırma kapsamında elde edilen karmaşıklık matrisi şekil 3'te gösterilmiştir.

Şekil 3. Karmaşıklık Matrisi



Kaynak: Bu görsel yazarlar tarafından oluşturulmuştur.

Çalışmada test verisiyle 1414 tahmin gerçekleştirilmiş ve gerçek değerler ile tahmin değerleri karşılaştırılmıştır. 1414 tahminde; 991 Mortalite, 160 canlılık doğru tahmin edilmiştir. (True Positive)

76 tahmin mortalite olmamasına rağmen mortalite olarak tahmin edilmiştir. (False Positive). 187 canlı olarak tahmin edilmesi gerekirken mortalite olarak değerlendirilmiştir (False Negative). 160 canlılık doğru tahmin edilebilmiştir. (True Negative)

Çalışmamızda oluşturulan modelin güvenilirlik (accuracy), hassasiyet (Sensitivity) ve özgüllük (Specificity) değerlendirmeleri yapılarak modelin kullanılabilirliği ölçülmüştür. Model değerlendirmeleri aşağıdaki tabloda gösterilmiştir.

4. BULGULAR

Veri setine Python 3.8 programlama dili kullanılarak tanımlayıcı istatistikler uygulanmış ve sonuç Microsoft Office Excel programı vasıtasıyla görselleştirilmiştir. Veri ön işleme aşamasında ihtiyaç duyulan veriler alınarak hazırlanan yeni veri setindeki kategorik ve numerik verilerin dağılımı gösterilmiştir.

Çalışma kapsamında değerlendirilen hastalara veriler incelendiğinde; örneklemin büyük çoğunluğunun (%37,0) Siyahi ve Latin (%37,2) ırktan bireylerden oluştuğu tespit edilmiştir. Hastalıkların ırk düzeyinde bireylerde farklı prognoza sebep olabileceği düşünüldüğünde; siyahi, latin, asya ve beyaz ırktan bireylere ait verilerin çalışmada değerlendirilmesi önem arz etmektedir. Kategorik verilere ait tanımlayıcı istatistikler tablo 6'da gösterilmiştir.

Tablo 6. Kategorik Verilere Ait Tanımlayıcı İstatistikler (0 ve 1 Etiketlerine Göre)

DEĞİŞKEN	FREKANS (0= HAYIR)	(%)	FREKANS (1= EVET)	(%)
YAŞAM DURUMU	3563	75,6	1148	24,4
SİYAHİ (IRK DEĞİŞKENİ)	2968	63,0	1743	37,0
BEYAZ (IRK DEĞİŞKENİ)	4245	90,1	466	9,9
ASYA (IRK DEĞİŞKENİ)	4590	97,4	121	2,6
LATİN (IRK DEĞİŞKENİ)	2958	62,8	1753	37,2
GEÇİRİLMİŞ KALP KRİZİ (MI)	4510	95,7	201	4,3
PERİFERİK DAMAR HASTALIĞI	3863	82,0	848	18,0
KONJESTİF KALP YETMEZLİĞİ	4170	88,5	541	11,5
KARDİOVASKÜLER HASTALIK	4205	89,3	506	10,7
DEMANS	4339	92,1	372	7,9
KOAH	4446	94,4	265	5,6
DİYABET	4216	89,5	495	10,5

DEĞİŞKEN	FREKANS (0= HAYIR)	(%)	FREKANS (1= EVET)	(%)
BÖBREK HASTALIĞI	3878	82,3	833	17,7
GEÇİRİLMİŞ İNME (SVO)	4653	98,8	58	1,2
NÖBET GEÇİRME	4673	99,2	38	0,8
BAYILMA ÖYKÜSÜ	4623	98,1	88	1,9
NÖROLOJİK HADİSE	4566	96,9	145	3,1
GEÇİRİLMİŞ BEYİN HASARI	4684	99,4	27	0,6

Veri setindeki numerik verilere ait ortalama ve standart sapma değerleri Tablo 7’de gösterilmiştir. Kullanılan veri setine göre; Covid-19 tanısı almış bireylerin yaş ortalaması ve standart sapması $63,36 \pm 16,70$ olarak belirlenmiştir. Laboratuvar değerleri değerlendirildiğinde özellikle enfeksiyon hastalarında referans değer aralıklarını aşan DDimer, Platelets, INR, Procalcitonin ve Ferritin gibi laboratuvar değerlerinin yüksek olduğu görülmüştür.

Tablo 7. Numerik Değişkenlere Ait Tanımlayıcı İstatistikler

DEĞİŞKEN	GÖZLEM SAYISI	ORTALAMA	STANDART SAPMA
YAŞ	4711	63,36	16,70
KAN O2 DEĞERİ	4711	89,59	18,97
ATEŞ	4711	35,81	7,73
MAP DEĞERİ	4711	81,74	24,49
DDİMER DEĞERİ	4711	3,22	5,26
PLTS DEĞERİ	4711	226,39	115,13
INR DEĞERİ	4711	1,10	0,99
BUN DEĞERİ	4711	27,19	31,21
CREATİNİNE DEĞERİ	4711	1,94	2,63
SODYUM DEĞERİ	4711	131,21	31,01
KAN ŞEKERİ	4711	127,80	131,01
AST DEĞERİ	4711	63,20	204,49
ALT DEĞERİ	4711	42,84	108,98
WBC DEĞERİ	4711	8,47	7,35
LENFOSİT DEĞERİ	4711	1,30	4,86
IL6 DEĞERİ	4711	125,03	2238,54
FERRİTİN DEĞERİ	4711	1056,68	3096,44
CRCTPROTEİN DEĞERİ	4711	10,31	11,22
PROCALCİTONİN DEĞERİ	4711	1,58	6,26
TROPONİN DEĞERİ	4711	0,05	0,26

Araştırmamızda yaş ve özellikle laboratuvar değerleri arasında bir ilişki olup olmadığının belirlenmesi açısından Pearson Korelasyon yöntemiyle hesaplanmış ve Şekil 4’te gösterilmiştir.

Şekil 4. Korelasyon Matrisi

	Age	Ossats	Temp	MAP	Ddimer	Pits	INR	BUN	Creatinine	Sodium	Glucose	AST	ALT	WBC	Lympho	IL6	Ferritin	CrtProtein	Procalcitonin	Troponin
Age	1.00	0.02	0.03	-0.06	0.14	-0.02	0.10	0.10	0.10	0.11	0.08	0.02	-0.01	0.04	-0.01	0.01	0.03	0.10	0.02	0.06
Ossats	0.02	1.00	0.82	0.52	0.01	0.13	0.10	0.08	0.06	0.11	0.08	0.02	0.03	0.06	0.02	0.01	0.01	-0.03	0.00	0.02
Temp	0.03	0.82	1.00	0.51	0.08	0.16	0.12	-0.04	0.07	0.05	0.11	0.03	0.05	0.09	0.03	-0.01	0.05	0.13	0.04	0.01
MAP	-0.06	0.52	0.51	1.00	-0.05	0.11	0.01	-0.04	-0.02	0.00	0.00	0.00	0.00	0.00	0.01	-0.05	0.00	-0.07	-0.05	-0.02
Ddimer	0.14	0.01	0.08	-0.05	1.00	0.10	0.10	0.22	0.12	0.12	0.08	0.07	0.11	0.18	-0.01	0.07	0.15	0.33	0.17	0.11
Pits	-0.02	0.13	0.16	0.11	0.10	1.00	0.09	0.08	0.02	0.34	0.13	0.03	0.01	0.27	0.03	-0.02	-0.03	0.09	-0.01	-0.01
INR	0.11	0.10	0.12	0.01	0.10	0.09	1.00	0.14	0.12	0.17	0.04	0.06	0.17	0.10	0.00	0.01	0.07	0.12	0.06	0.19
BUN	0.25	0.08	0.07	-0.04	0.22	0.08	0.14	1.00	0.62	0.27	0.29	0.07	0.06	0.17	-0.00	0.03	0.10	0.11	0.13	0.11
Creatinine	0.10	0.06	0.07	-0.02	0.12	0.02	0.12	0.62	1.00	0.14	0.05	0.04	0.04	0.06	-0.02	0.02	0.17	0.12	0.20	0.16
Sodium	0.11	0.37	0.41	0.22	0.12	0.34	0.17	0.27	0.14	1.00	0.22	0.05	0.06	0.20	0.05	-0.01	0.04	0.11	0.02	0.03
Glucose	0.11	0.08	0.11	0.10	0.08	0.13	0.04	0.29	0.05	0.22	1.00	-0.01	-0.01	0.11	0.00	-0.00	0.02	0.05	0.01	-0.00
AST	0.02	0.02	0.04	-0.05	0.07	0.03	0.06	0.07	0.04	0.05	0.05	1.00	0.48	0.06	-0.00	0.01	0.10	0.06	0.09	0.03
ALT	-0.01	0.03	0.05	0.00	0.11	0.01	0.17	0.06	0.04	0.06	-0.01	0.48	1.00	0.08	0.00	0.02	0.15	0.05	0.06	0.39
WBC	0.04	0.06	0.09	0.00	0.18	0.27	0.10	0.17	0.06	0.20	0.11	0.06	0.08	1.00	0.75	0.02	0.05	0.18	0.10	0.08
Lympho	-0.01	0.02	0.03	0.01	-0.01	0.03	0.00	-0.00	-0.02	0.05	0.00	-0.00	0.00	0.75	1.00	-0.00	-0.00	-0.02	-0.01	-0.00
IL6	0.01	-0.01	-0.01	-0.05	0.07	-0.02	0.01	0.03	0.02	-0.01	-0.00	0.01	0.02	0.02	-0.00	1.00	0.01	0.03	0.09	0.01
Ferritin	0.03	0.01	0.05	-0.05	0.15	-0.03	0.07	0.10	0.17	0.04	0.02	0.10	0.15	0.05	-0.00	0.01	1.00	0.18	0.20	0.22
CrtProtein	0.10	-0.03	0.13	-0.07	0.33	0.09	0.12	0.11	0.12	0.11	0.05	0.06	0.05	0.18	-0.02	0.03	0.18	1.00	0.27	0.04
Procalcitonin	0.02	0.00	0.04	-0.05	0.17	-0.01	0.06	0.13	0.20	0.02	0.01	0.09	0.06	0.10	-0.01	0.09	0.20	0.27	1.00	0.08
Troponin	0.06	0.02	0.01	-0.02	0.11	-0.01	0.19	0.11	0.16	0.03	-0.00	0.03	0.39	0.08	-0.00	0.01	0.22	0.04	0.08	1.00

5. SONUÇ

Covid-19 hastalığında başta akciğer ve diğer sistemlerde viral tutulum belirli bir süre içerisinde gerçekleşir. Bu süre içerisinde hastaların etkin bir şekilde tedavi edilememesi, prognozun kötü seyretmesine ve mortalite oranlarının artmasına sebep olabilmektedir. Bu sebeple özellikle klinisyenlerin veya sağlık profesyonellerinin hastanın laboratuvar değerleri başta olmak üzere çalışmada da gösterilen parametreleri takip ederek mortalite riskini hesaplaması sağlanabilmektedir. Çalışmada sağlık profesyonellerine özellikle hastalık sürecinin başlangıç aşamasında olan bireylerin mortalite risklerinin belirlenmesinde yardımcı olmak (Karar Ağacı Modellemesiyle %83,5 oranında mortalite riski hesaplanması) ve etkin tedavi şansı yaratarak mortalite riskinin azaltılması amaçlanmıştır.

Bu araştırmaya dayanak olarak hazırlanan modellemelerde yeni hastaların demografik ve klinik verileri ile ölüm riski %83,5 güvenilirlikle hesaplanabilmektedir. Dolayısıyla benzer modelleme yöntemini kullanarak klinisyenler, yeni hastaların ölüm riskini belirleyebilir ve hastaları durumlarına göre bilimsel dayanak doğrultusunda önceliklendirebilirler.

Araştırma kapsamında elde edilen bulgular ışığında; Covid-19 tanısı almış bireylerin genellikle yaşlı bireyler ($63,36 \pm 16,70$) olduğu görülmüştür. Laboratuvar değerleri değerlendirildiğinde özellikle enfeksiyon hastalarında referans değer aralıklarını aşan DDimer, Platelets, INR, Procalcitonin ve Ferritin gibi laboratuvar değerlerinin yüksek olduğu tespit edilmiştir. Bu sebeple söz konusu yaş aralığındaki ve enfeksiyon parametrelerinin ilk etapta değerlendirilerek mortalitesi yüksek olan bu hastalara öncelik verilebileceği düşünülmektedir. Örneklemin büyük çoğunluğunun (%37,0) Siyahi ve Latin (%37,2) ırktan bireylerden oluştuğu tespit edilmiştir. Bu çalışmada seçilen örneklem verisi ile sosyodemografik özellikleri farklı ülkelerde yapılacak benzer çalışmalarda kullanılacak hasta verisinin ırk düzeyinde elde edilen sonuçlar üzerinden farklılıklara sebep olabileceği düşünülmektedir.

Multidisipliner düzeyde sağlık bilimine entegre edilecek modellemeler aracılığıyla oluşturulacak web tabanlı karar destek modülleri vasıtasıyla klinisyenler veya diğer sağlık profesyonellerine kılavuz niteliğinde karar destek çıktıları oluşturulabilir.

Sağlık otoriteleri ve hastane yöneticileri açısından düşünüldüğünde; servis yatak doluluğu, yoğun bakım yatak planlaması gibi önemli göstergeler, durumu ciddileşecek hastaların önceden tahmin edilmesi sebebiyle daha etkili planlanabilecektir.

Bilimsel dayanak doğrultusunda hastalar mortalite risklerine göre sınıflandırıldığından hastalara göre tedavi düzenlemesi yapılabileceği düşünülmektedir. Bu sebeple diğer hastalara göre hafif düzeyde hastalık seyri yaşayacağı hesaplanan hastalarda agresif tedavi yönteminin kullanılmaması bireyi sağlık açısından koruyacak ve ihtiyacı olan hastaların tedavisinin geciktirilmeden yapılmasına olanak sağlayacaktır. Dolayısıyla gereksiz sağlık harcamalarının, tanı, test ve diğer tıbbi prosedürlerin önüne geçilebilir.

YAZARLARIN BEYANI

Katkı Oranı Beyanı: Yazarlar çalışmaya eşit oranda katkı sağlamıştır.

Destek ve Teşekkür Beyanı: Çalışmada herhangi bir kurum ya da kuruluştan destek alınmamıştır.

Çatışma Beyanı: Çalışmada herhangi bir potansiyel çıkar çatışması söz konusu değildir.

KAYNAKÇA

- Ahmad, I. ve Asad, S. M. (2020). Predictions of coronavirus COVID-19 distinct cases in Pakistan through an artificial neural network. *Epidemiology & Infection*, 148(e222), 1-10.
- Alaa, A. M., Bolton, T., Di Angelantonio, E., Rudd, J. ve van der Schaar, M. (2019). Cardiovascular disease risk prediction using automated machine learning: A prospective study of 423,604 UK Biobank participants. *PloS one*, 14(5), 1-17.
- Alballa, N. ve Al-Turaiki, I. (2021). Machine learning approaches in COVID-19 diagnosis, mortality, and severity risk prediction: A review. *Informatics in Medicine Unlocked*, 24(2021), 1-17.

- Altschul, D. J., Unda, S. R., Benton, J., Ramos, R., Mehler, M. ve Eskandar, E. (2021). Mortality incidence, sociodemographic and clinical data in COVID-19 patients. Figshare, Dataset. <https://doi.org/10.6084/m9.figshare.12685475.v1>
- Ayaz, M. (2021). *Makine öğrenmesi algoritmaları ile covid-19 hastalarının belirlenmesi* [Yüksek Lisans Tezi]. Pamukkale Üniversitesi.
- Breiman, L., Friedman, J. H., Olshen, R. A., ve Stone, C. J. (2017). *Classification and regression trees*. Routledge.
- Brijain, M., Patel, R., Kushik, M. R. ve Rana, K. (2014). A survey on decision tree algorithm for classification.
- Connor, C. W. (2019). Artificial Intelligence and Machine Learning in Anesthesiology. *Anesthesiology*, 131(6), 1346–1359.
- DeGregory, K. W., Kuiper, P., DeSilvio, T., Pleuss, J. D., Miller, R., Roginski, J. W., Fisher, C. B., Harness, D., Viswanath, S., Heymsfield, S. B., Dungan, I. ve Thomas, D. M. (2018). A review of machine learning in obesity. *Obesity reviews: An official journal of the International Association for the Study of Obesity*, 19(5), 668–685.
- Deo, R. C. (2015). Machine Learning in Medicine. *Circulation*, 132(20), 1920–1930.
- Henwood, A. F. (2020). Coronavirus disinfection in histopathology. *Journal of histotechnology*, 43(2), 102-104.
- Jaskari, J., Myllärinen, J., Leskinen, M., Rad, A. B., Hollmén, J., Andersson, S. ve Särkkä, S. (2020). *Machine learning methods for neonatal mortality and morbidity classification*. IEEE Access, 8, 123347-123358.
- Kilic, A., Goyal, A., Miller, J. K., Gleason, T. G. ve Dubrawski, A. (2021). Performance of a machine learning algorithm in predicting outcomes of aortic valve replacement. *The Annals of Thoracic Surgery*, 111(2), 503-510.
- Kim, M. J. (2021). Building a Cardiovascular Disease Prediction Model for Smartwatch Users Using Machine Learning: Based on the Korea National Health and Nutrition Examination Survey. *Biosensors*, 11(7), 228.
- Li, W. T., Ma, J., Shende, N., Castaneda, G., Chakladar, J., Tsai, J. C., Apostol, L., Honda, C. O., Xu, J., Wong, L. M., Zhang, T., Lee, A., Gnanasekar, A., Honda, T. K., Kuo, S. Z., Yu, M. A., Chang, E. Y., Rajasekaran, M. R. ve Ongkeko, W. M. (2020). Using machine learning of clinical data to diagnose COVID-19: a systematic review and meta-analysis. *BMC Medical Informatics and Decision Making*, 20(1), 247.
- Matsuo, K., Aihara, H., Nakai, T., Morishita, A., Tohma, Y. ve Kohmura, E. (2020). Machine learning to predict in-hospital morbidity and mortality after traumatic brain injury. *Journal of neurotrauma*, 37(1), 202-210.
- McAvaney, B. J., Covey, C., Joussaume, S., Kattsov, V., Kitoh, A., Ogana, W. ve Zhao, Z. C. (2001). Model evaluation. In *Climate Change 2001: The scientific basis. Contribution of WG1 to the Third Assessment Report of the IPCC (TAR)* (s. 471-523). Cambridge University Press.
- Moulaei, K., Shanbehzadeh, M., Mohammadi-Taghiabad, Z. ve Kazemi-Arpanahi, H. (2022). Comparing machine learning algorithms for predicting COVID-19 mortality. *BMC Medical Informatics and Decision Making*, 22(1), 2.
- Muhyaddin, R., Abd-Alrazaq, A. A., Househ, M., Alam, T. ve Shah, Z. (2020). The Impact of Clinical Decision Support Systems (CDSS) on Physicians: A Scoping Review. *Studies in Health Technology and Informatics*, 272, 470–473.
- National Health Commission of the PRC. (2021). *Features, transmission, symptoms and mortality rate*. http://en.nhc.gov.cn/2020-03/01/c_77162.htm adresinden 9 Kasım 2021 tarihinde alınmıştır.
- Oh, J., Yun, K., Maoz, U., Kim, T. S. ve Chae, J. H. (2019). Identifying depression in the National Health and Nutrition Examination Survey data using a deep learning algorithm. *Journal of Affective Disorders*, 257, 623–631.
- Pollard, S., Bansback, N. ve Bryan, S. (2015). Physician attitudes toward shared decision making: A systematic review. *Patient Education and Counseling*, 98(9), 1046–1057.

- Rosenstock, I. M. (2005). Why people use health services. *The Milbank Quarterly*, 83(4),1-32.
- Saber, H., Somai, M., Rajah, G. B., Scalzo, F. ve Liebeskind, D. S. (2019). Predictive analytics and machine learning in stroke and neurovascular medicine. *Neurological Research*, 41(8), 681–690.
- Sapra, A., Malik, A. ve Bhandari, P. (2021). *Vital sign assessment*. StatPearls Publishing.
- Sreepadmanabh, M., Sahu, A. K. ve Chande, A. (2020). COVID-19: Advances in diagnostic tools, treatment strategies, and vaccine development. *Journal of biosciences*, 45(1), 148. <https://doi.org/10.1007/s12038-020-00114-6>
- Şahin, Ö. S., Üçer, M., Özyaydın, B.ve Doğan, I. (2018). Nöroşirürji’de yapay zekâ ve insan zekası. *Türk Nöroşirürji Dergisi*, 28(3), 277-283.
- Vens, C., Struyf, J., Schietgat, L., Džeroski, S. ve Blockeel, H. (2008). Decision trees for hierarchical multi-label classification. *Machine learning*, 73(2), 185-214.
- Visa, S., Ramsay, B., Ralescu, A. L. ve Van Der Knaap, E. (2011). Confusion matrix-based feature selection. *MAICS*, 710, 120-127.
- Wang, P., Zheng, X., Li, J.ve Zhu, B. (2020). Prediction of epidemic trends in COVID-19 with logistic model and machine learning technics. *Chaos, Solitons & Fractals*, 139, 110058.
- Wirth, R. ve Hipp, J. (2000, April). CRISP-DM: Towards a standard process model for data mining. *Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining* (s. 29-40).
- World Health Organization. (2022). <https://www.who.int/data> adresinden 22 Şubat 2022 tarihinde alınmıştır.
- Wu, C. C., Yeh, W. C., Hsu, W. D., Islam, M. M., Nguyen, P. A. A., Poly, T. N., ... ve Li, Y. C. J. (2019). Prediction of fatty liver disease using machine learning algorithms. *Computer Methods and Programs in Biomedicine*, 170, 23-29.
- Zhang, Y., Coecke, B.ve Chen, M. (2019). On the cost of interactions in interactive visual machine learning. *2019 IEEE workshop on Evaluation of Interactive Visual Machine Learning systems (Eviva-ML)*. IEEE.
- Zheng, Y., Zhu, Y., Ji, M., Wang, R., Liu, X., Zhang, M., Liu, J., Zhang, X., Qib, C.H., Fang, L. ve Ma, S. (2020). A learning-based model to evaluate hospitalization priority in COVID-19 pandemics. *Patterns*, 1(6),1-10.