

## COVID-19 DÖNEMİNDE HAVACILIKTA STRATEJİK YÖNETİM VE UÇUŞ VERİLERİNİN İNCELENMESİ

Zekeriya ŞAHİN\* & Ekrem SÜZEN\*\*

### Öz

2019 yılının Aralık ayında Çin'in Wuhan kentinde ortaya çıkan COVID-19 salgını günümüz dünyasında hemen her sektörü önemli ölçüde etkilemiştir. Dünya Sağlık Örgütü tarafından pandemi olarak ilan edilen COVID-19, havayolu taşımacılığını da etkilemiştir ve etkilemeye devam etmektedir. 2020 yılı itibariyle dünya ülkeleri tarafından havayolu taşımacılığında çeşitli tedbirler alınmıştır. Bu durum havayolu taşımacılığının, gerek sosyal durumu gerekse ekonomik açıdan etkilenmesine yol açmıştır. SARS salgınından bu yana en büyük salgın hastalık olan COVID-19, sivil havacılıkta insani tedbirlere; maske kullanımına, sosyal mesafe kuralına ve dezenfektan zarurietine yol açmıştır. Ayrıca dünya ülkelerinin de etkilendiği gibi Türkiye de sivil havacılık bağlamında etkilenen ülkelerden biridir. Bu çalışmada ise Covid-19 döneminden önce ve sonra uçuş verileri analiz edilmiştir. UKVH ile uçuş tahminleme modeli hafıza hücresi kullanılarak bir önceki adıma ait bilgiler depolanarak sonuçlar elde edilmiştir. DÖSA modeli, sayısal olarak UKVH'den daha iyi sonuçlar vermiştir. Ancak, DÖSA ve UKVH arasında doğruluk oranı bakımından ayırt edici bir fark tespit edilmemiştir.

**Anahtar Kelimeler:** Covid-19, Havacılık Yönetimi, Stratejik Yönetim, Uçuş Verileri, Derin Öğrenme.

## STRATEGIC MANAGEMENT AND INVESTIGATION OF FLIGHT DATA IN AVIATION IN THE PERIOD OF COVID-19

### Abstract

The COVID-19 emerged in the city of Wuhan, China in December 2019 has significantly affected almost every sector in today's world. COVID-19, declared as a pandemic by the World Health Organization, has also affected and continues to affect air transportation. As of 2020, various measures have been taken in air transportation by countries around the world. This situation has led to the impact of air transportation, both socially and economically. COVID-19, the largest epidemic disease since the SARS outbreak, has led to human measures in civil aviation such as

\* Dr. Öğr. Üyesi, Milli Sav. Üniversitesi Kara Harp Okulu, Savunma Yönetimi Bölümü, zshahin2@msu.edu.tr, <https://orcid.org/0000-0002-2811-3264>

\*\* Dr. Öğr. Üyesi, İstanbul Gelisim Üniversitesi MYO, esuzen@gelisim.edu.tr, <https://orcid.org/0000-0002-2811-3264>

*mask use, social distancing, and the necessity of disinfectants. In addition, Türkiye, like other countries in the world, is one of the countries affected in terms of civil aviation. In this study, flight data before and after the Covid-19 period was analyzed. The flight prediction model with UKVH used memory cells to store information from the previous step to obtain results. The DÖSA model provided better numerical results than UKVH. However, no distinctive difference was found between DÖSA and UKVH in terms of accuracy rate.*

**Keywords:** *Covid-19, Aviation Management, Strategic Management, Flight Data, Deep Learning.*

## **Giriş**

Amerika Birleşik Devletleri Ulaştırma Bürosu tarafından açıklanan son verilere göre, 2020 yılında gerçekleşen tüm uçuşların %14,69'u gecikme ya da iptaller nedeniyle zamanında gerçekleşemedi. Bunların %0,19'u ise yönlendirme (uçanın planlanan havalimanından farklı bir havalimanına iniş yapması) nedeniyle gerçekleşti. Gecikmeler ve iptaller, havayolu şirketleri için ciddi mali kayıplara neden olmakta ve yolcu memnuniyetsizliğine yol açmaktadır. Bu nedenle, birçok ülke, vatandaşlarının bu tür sorunlardan kaynaklanan zararlarını gidermek için caydırıcı kanuni düzenlemeler yapmış ve ilgili havayolu şirketlerine parasal cezalar uygulamıştır. Ancak, bu yaptırımlara rağmen, uçuşlarda hala sık sık gecikme ve iptaller yaşanmaktadır. IATA tarafından belirlenen ticari yolcu uçuşları kapsamındaki gecikme kodları, uygun olmayan hava koşulları, hava trafiğinden kaynaklanan yoğunluk, havalimanı kapasitesi, teknik ve mekanik sorunlar, ulusal havacılık sistemleri ve güvenlik gibi nedenlerle uçuş gecikmelerinin başlıca sebepleri olarak kabul edilir.

Uçuşlar için geliştirilecek gecikme tahmin sistemlerinin kullanılmasıyla gecikmeden kaynaklı maliyetlerin azaltılması mümkün olmakta ve firmalar milyar dolarlık tasarruf edebilmektedirler. Özellikle öğrenme özelliği bulunan uyarı sistemleri ile gecikmeler önceden tahmin edilebilir. Gecikme tahmin sonuçları yolcu, havalimanı ve havayolu firması ile anlık paylaşılarak gerekli önlem ve planlamalar uçuş öncesinde alınabilir. Bu sayede risk planlamasına da önemli katkıları olabilir. Bu kapsamda, Federal Havacılık Kurulu'nun (FAA) uçuş planlamaları ve gecikmelerden kaynaklanan maliyetleri azaltmak için çalışmalar bulunmaktadır (Belcastro vd., 2016).

COVID-19 pandemisi, havacılık sektöründe büyük bir krize neden oldu. Pandeminin etkileri, hem hava yolu şirketleri hem de havaalanları için büyük bir ekonomik kayıp ve iş kaybına neden oldu. Pandeminin havacılık sektörüne etkileri aşağıdaki gibi özetlenebilir:

**Seyahat Kısıtlamaları:** Pandemi nedeniyle, birçok ülke sınırlarını kapattı ve uluslararası seyahatler sınırlı hale geldi. Bu, hava yolu şirketlerinin uçuşlarını azaltmasına ve bazı durumlarda tamamen durdurmasına neden oldu.

**Düşen Yolcu Sayısı:** Pandemi nedeniyle, insanların seyahat etme istekleri azaldı ve birçok kişi seyahatlerini iptal etti. Bu da hava yolu şirketlerinin yolcu sayılarında büyük düşüslere neden oldu.

**Uçuş İptalleri:** Havacılık sektöründeki kriz nedeniyle, hava yolu şirketleri birçok uçuşu iptal etmek zorunda kaldı. Bu da yolcular için büyük bir sıkıntı ve ayrıca hava yolu şirketleri için büyük bir mali kayıp anlamına geldi.

**İş Kayıpları:** Hava yolu şirketleri, pandemi nedeniyle gelirlerinde büyük düşüsler yaşadı ve birçok şirket işlerini sürdürmek için işçi çıkarmak veya ücretleri kesmek zorunda kaldı.

**Maliyet Artışları:** Pandemi nedeniyle, hava yolu şirketleri için hijyenik önlemler ve sağlık kontrolleri gibi ek maliyetler ortaya çıktı. Bu da sektördeki maliyetleri artırdı.

**Uçuş Güvenliği:** Pandemi nedeniyle, uçuş güvenliği konusunda yeni önlemler alınması gerekiyor. Bu da hava yolu şirketlerinin uçuşlarını planlama ve yönetme şekillerinde değişiklikler yapmalarını gerektiriyor.

Pandeminin etkisiyle, havacılık sektörü çok büyük bir değişim yaşadı. Şirketler, yeni stratejiler geliştirmek ve maliyetleri azaltmak için çalışıyorlar. Ayrıca, pandemi sonrası dönemde değişen seyahat trendleri ve tüketici beklentileri de dikkate alınarak, havacılık sektörü önemli bir dönüşüm sürecine giriyor.

## 1. LİTERATÜR TARAMASI

Bu konuyla ilgili literatürde birçok çalışma yapılmıştır ve uçuş gecikmesi, ticari havacılık endüstrisindeki hava taşıma sistemlerinin kritik bir performans göstergesi olarak kabul edilmektedir. Yaklaşık olarak %87,5'i 2000'li yıllarda gerçekleştirilen ve 2007 ile 2017 yılları arasında yayımlanan akademik çalışmalar, uçuş gecikmelerinin tahmin edilmesiyle ilgilidir ve çoğunlukla Makine Öğrenmesi algoritmaları ve Veri Madenciliği metotları kullanılarak gerçekleştirilmiştir (Sternberg vd., 2017). Araştırmacılar, uçuş gecikmelerini farklı açılardan ele almaktadır, örneğin havalimanı planlamasının optimizasyonu, havalimanı kapasite artırımı, tesisin yeri, uçuş değişikliği ve uçuş iptali gibi.

Kang ve Hansen (2017) tarafından gerçekleştirilen bir çalışmada, 5 büyük ABD merkezli havayolunun verileri kullanılarak, SBT ayarlama kararlarının on-time (zamanında) ve erken varış verileri üzerindeki etkileri araştırılmıştır. Çalışmada, iki yıl boyunca gerçekleştirilen uçuşlar için SBT'deki değişiklikler modellenmiştir. Uçuş verileri, Ocak 2008'den Nisan 2014'e kadar olan dönemi kapsayan FAA ve ASPM veri tabanlarından elde edilmiştir. Kullanılan yöntemler bölümünde, her havayolunun farklı tercihlerini ve alternatifler arasındaki olası korelasyonu yakalamak için karışık bir logit modeli kullanılmıştır. Her bir alternatif ayarlama için zamanında ve erken varış özellikleri üretilmiştir. Karışık logit modelleri, bu

özelliklere ve seçilen blok zaman ayarına göre tahmin edilmiştir. Sonuç olarak, MNT bazında yapılan ölçümler diğerlerine göre daha yüksek çıkmıştır.

Kenan, Jebali ve Diabat (2018) tarafından yapılan araştırmada, uçuş planlaması, filo tahsisi ve uçak yönlendirme problemleri, gecikmeler gibi gerçekçi faktörler göz önünde bulundurularak formüle edilmiştir. Bakım rotası, uçakların rotalarının başlangıç noktasında bitirilmesi için dolaylı olarak hesaba katılmıştır. Çözüm için çok sayıda değişken içeren bir sütun tabanlı formülasyon kullanılmıştır. Veri seti, 228 uçuş noktası ve 45 farklı varış noktasından oluşmaktadır ve 59 farklı uçak tipi kullanılmıştır. Bu çalışmada, entegre uçuş planlaması, filo tahsisi ve uçak yönlendirme problemleri için iki aşamalı stokastik programlama modeli geliştirilmiştir. Modelin yüksek karmaşıklığından dolayı, ticari bir çözücü olan CPLEX, büyük örneklerin çözümlenmesinde yetersiz kalmıştır. Bu nedenle, üç sütun üretimi tabanlı yaklaşım kullanılmıştır ve bu yaklaşımlar, CPLEX'e göre daha üstün sonuçlar vermiştir. Elde edilen sonuçlar, havayolu şirketleri üzerindeki etkileri için bir duyarlılık analizi ile de incelenmiştir.

Yazdi, Dutta ve Steven'in (2017) yürüttüğü araştırma, bagaj ücretlerinin havayolu endüstrisindeki gecikmelerle olan ilişkisini incelemektedir. Veri seti olarak ABD Ulaştırma Bakanlığı Ulaştırma İstatistikleri Bürosu'ndan 46 çeyreklik bir panel veri seti kullanılmıştır. Bu veri seti 2003 yılından 2014'ün son çeyreğine kadar devam etmektedir. Zamanında Performans veritabanı, büyük hava taşıyıcılarının kesintisiz iç hat uçuşları hakkında bilgi sağlamaktadır ve uçuş seviyesindeki gecikmeleri beş farklı neden kategorisine ayırmaktadır: Taşıyıcı Gecikme, Hava Gecikmesi, Güvenlik Gecikmesi, Geç Uçak Gecikmesi ve Ulusal Hava Sistemi Gecikmesi. Araştırmada, Bagaj Ücretleri (BF) uçuş zamanına göre düzenlenerek gecikmelere etkisi araştırılmıştır. On tanesi bagaj ücreti uygulayan on bir taşıyıcı incelenmiştir. Sonuçlar, BF'nin zamanında performansı artırdığını göstermektedir. Araştırma ayrıca, gelişmelerin rota üzerindeki hub-havalimanları ve yolcuların eğlence veya iş olarak sınıflandırılmasından etkilendiğini ortaya koymaktadır. Zamansal analiz, uygulamanın ilk aşamasının daha fazla uçuş gecikmesine yol açabileceğini, ancak tam uygulamanın gerçekten iyileştirdiğini ve hala geç uçuşları iyileştirdiğini göstermektedir.

Kim ve diğerleri (2016) havacılık endüstrisindeki gecikmeleri azaltmak için farklı bir yöntem olan Tekrarlayan Nöral Ağlar (RNN) kullanarak, Ulusal Okyanus ve Atmosferik İdaresinin hava durumu verilerini analiz etmiştir. Çalışmada, gecikmeli uçuşların kalkış ve varış saatlerini tahmin etmek amaçlanmıştır. McCarran Uluslararası Havaalanı'nda elde edilen sonuçlar %91.81 doğruluk oranı gösterirken, Sky Harbor Uluslararası Havalimanı'nda veri hacmindeki farklılıklar nedeniyle %71,34 doğruluk oranı elde edilmiştir.

Choi ve ekibi (2016) çalışmalarında, uçuş gecikmeleri ve hava durumu arasındaki ilişkiyi incelemişlerdir. Hava durumu verileri Ulusal Okyanus ve Atmosferik İdaresi tarafından sağlanmıştır. Araştırmalarının sonucunda, Random Forest algoritmasının önerildiği bir topluluk öğrenme yöntemi ile

varış gecikmesinin %80,36 doğruluk oranıyla tahmin edilebileceği bulunmuştur.

Belcastro ve diğerleri (2016) kötü hava koşullarının uçuş gecikmelerine neden olduğunu ele alarak, MapReduce yöntemiyle Random Forest kullanarak tahmin etmişlerdir. Bu çalışmada Ulusal Okyanus ve Atmosfer İdaresi'nden elde edilen hava durumu verileri kullanılmıştır. Elde edilen sonuçlara göre, 15 dakikalık bir gecikme eşiği için %74,2 doğruluk ve %71,8 hatırlama oranı, 60 dakikalık bir eşik için ise %85,8 doğruluk ve %86,9 hatırlama oranı elde edilmiştir.

Thiagarajan ve diğerleri (2017), World Weather Online API servisi üzerinden hava durumu verilerini kullanarak uçuş gecikmelerini tahmin etmiştir. Bu çalışmada Gradient Boosting tekniği kullanılmıştır. Varış gecikmelerinde %94,35 accuracy (kesinlik) ve kalkış gecikmelerinde %86,48 accuracy (kesinlik) oranı elde edilmiştir.

Prasad ve diğerleri (2016) Thiagarajan ve arkadaşlarının aynı veri kaynağından yararlanarak uçuş gecikmelerini tahmin etme çalışmaları yapmışlardır. Ancak, Thiagarajan ve arkadaşları Gradient Boosting yöntemini kullanırken, Prasad ve arkadaşları Decision Tree ve Regression yöntemlerini kullanmışlardır. Prasad ve arkadaşları sınıflandırma yöntemiyle %78 başarı elde ederken, regresyon yöntemiyle %77 başarı elde etmişlerdir.

Yu vd. tarafından yapılan çalışmada (2019), PEK havalimanına ait Ocak 2017 ve Mart 2018 arasında gerçekleşen kalkış ve varış uçuş gecikme verileri kullanılarak DBN-SVR tahminleme yöntemiyle accuracy oranı %93, k-NN ile %87, Support Vector Machine ile %87 ve son olarak Logistic Regression ile %82 olarak hesaplanmıştır.

Manna ve ark. (2017), istatistiksel yaklaşım metodunu benimsemiş olup, Gradient Boosted Decision Tree sınıflandırıcısı kullanarak, ABD Ulaştırma Bakanlığına ait olan Nisan-Ekim 2013 periyodundaki en yoğun 70 havalimanındaki uçuş gecikme veri seti üzerinde varış gecikmelerinde yaklaşık olarak %92 accuracy kalkış gecikmelerinde ise yaklaşık %94 accuracy oranı elde etmişlerdir.

## **2. COVID-19 PANDEMİSİNİN HAVACILIK SEKTÖRÜNE ETKİLERİ**

Havacılık sektörü, dünya çapındaki taşımacılık sektörleri arasında önemli bir yer tutar ve birçok ülke için hayati bir öneme sahiptir. Ancak, COVID-19 pandemisi nedeniyle sektörde önemli bir gerileme yaşanmıştır ve hava trafiği, hastalığın başka bölgelere yayılmasının potansiyel bir yolu olarak görülmektedir. Bu durumda, havacılık endüstrisi operasyonlarını devam ettirebilmek için çok az seçeneğe sahiptir. Yaşanan bu şok, ekonomik açıdan kırılmalı bir dönemden geçilmesine neden olmuştur (Dube vd., 2021). COVID-19'un yayılmasına karşı verilen mücadelede, ülkeler arasında farklı gelişmeler yaşanmıştır. Hükümetler, hastalığın yayılmasını kontrol altında tutmak için

havacılık sektörüne doğrudan etkisi olan ulusal ve uluslararası hava trafiğine sınırlamalar getirmişlerdir. Enfekte vatandaşların sayısında hızlı bir artış görülen birçok ülke, uçuşları askıya alarak ve havaalanlarını kapatarak ülke genelinde karantina uygulamasına devam etme kararı almıştır (Gössling vd., 2020). Virüsün ilk tespit edildiği andan itibaren Çin, karantina uygulayarak diğer ülkelere öncülük etti. Bu uygulama, birkaç başka ülkeyi de sokağa çıkma yasağı ilan etmeye yönlendirdi ve ABD de resmi bir seyahat uyarısı yayınladı. Avrupa Birliği ülkeleri de sınır kapatmaları ile tepki vererek, yalnızca AB vatandaşlarının anavatanlarına dönmesine izin verdi ve geri kalan yolcuları yasakladı. Bu ani yavaşlama, havacılık endüstrisinin büyümesi ve genişlemesi için önemli bir engel haline geldi. Bu nedenle, istihdam yaratmak ve ekonomik refahı artırmak için atılması gereken önemli adımlar var. (Avrupa Komisyonu, 2020).

Havacılık sektörü, COVID-19 pandemisi nedeniyle önemli bir gerileme yaşadı ve bu da birçok sonuç doğurdu. İlk olarak, kapasite düşüşleri ve düşük talep sektör üzerindeki baskıyı artırdı. Bu durum, istihdam açısından da olumsuz sonuçlar doğurdu. İkinci olarak, müşteri yönetiminden sorumlu havayolu çalışanları en fazla risk altında olanlardı. Üçüncü olarak, pandemi nedeniyle havayollarının yolcusuz uçuşlara devam etmesi istenmeyen sonuçlara yol açtı. Dördüncü olarak, işgücü maliyetleri düşerken sektörde istihdam edilenlerin maaşları ve havayollarından elde edilen gelirler de düşüyor. Beşinci olarak, COVID-19, havacılık işlerinin tüm ekonomi için getirebileceği avantajlar üzerinde zararlı bir etkiye sahip olduğunu göstermiştir. Bu durum, havacılık istihdamında önemli bir değişime neden oldu ve her havacılık çalışanınin ürettiği brüt katma değer yüzdesinin daha büyük bir kayıp yaşamasına neden oldu. (IATA, 2020).

Koronavirüs krizi ve sınırlı uçuş programlarının bir sonucu olarak, havayolu filoları uzun süre yerde kalıyor. Uçakların iyi koşullarda tutulmasıyla ilgili harcamalar ve park etme maliyetleri gibi taşınması gereken diğer bazı ödenmemiş maliyetler vardır (Adrienne vd., 2020). Havayolları, endüstrinin karşı karşıya olduğu bu zorlu zamanlarda hayatta kalmaya çalışırken, uçakları nerede saklayacakları konusunda giderek daha fazla mücadele ediyor. Havayolu şirketleri, COVID-19 pandemisi nedeniyle uçak talebinin azalması ile mücadele ederken, bazıları eski uçakların daha erken emekliye ayrılmasını planlamaktadır (Adrienne vd., 2020). Bu durum, Airbus ve Boeing gibi uçak üreticileri için önemli ölçüde düşük talep anlamına gelmektedir (Dube vd., 2021). Havacılık endüstrisinde, belirsizlik seviyesi oldukça yüksektir. Boeing, üretimini önemli ölçüde azaltmak zorunda kalmıştır (KPMG, 2021).

Uçak kiralama sektörü, özellikle küçük ve orta ölçekli işletmeler, mali kayıpların yanı sıra uçakların geri alınması nedeniyle sıkıntı yaşıyor (Garratt vd., 2020). Ayrıca, uçak kiralama şirketleri, pandemi nedeniyle havayollarının ödeme yapamama riskine karşı daha sıkı kredi standartları uygulamak zorunda kalıyor (Grant Thornton, 2020). Bu, kiralama şirketlerinin özellikle de küçük

işletmelerin daha büyük kayıplar yaşamasına neden olabilir (PwC, 2020). Pandemi nedeniyle düşen uçak talebi, uçak kiralama şirketlerinin de kiralamalarını azaltması veya uçak filolarını küçültmesi gerektiğinden, uzun vadeli iş planlamalarını olumsuz etkilemektedir (Dube vd., 2021).

Ticari havacılık sektörü, yük taşımacılığı ve tıbbi malzeme tedarikini de kapsayan geniş bir alandır. Şubat 2020'ye kadar, belirli bir süre içinde büyümeye devam ediyordu. Ancak pandeminin etkisiyle, kilometre başına yolcu geliri metrikleri keskin bir düşüş yaşadı ve 2020'de hava yoluyla seyahat eden kişilerin harcamalarında yaklaşık %60'luk bir düşüş gözlemlendi (IATA, 2020). Mart 2020'nin sonunda, toplam hava taşımacılığı hizmetleri sayısı -%55 düştü ve Nisan ayına kadar tarifeli uçuş bağlantılarının sayısı %74'e kadar geriledi. Bazı ülkeler, yalnızca özel amaçlar için seyahate izin verirken, diğerleri hem gelen hem de giden uçuşları kısıtladı veya tamamen yasakladı. Toplam uçuş bağlantı sayısı 38,9 milyondan 23 milyona düşerek, temsil edilen yüzde değişimi %40,6'ya ulaştı. Kilometre başına yolcu geliri metriklerinde de önemli bir düşüş yaşandı, yaklaşık %66 oranında bir azalma görüldü. Sınır ötesi seyahat için yolcu talebi de kabaca %76 oranında azaldı (HospitalityNet, 2021).

Koronavirüs krizi, havacılık sektörü için oldukça zorlu bir dönemi beraberinde getirdi. Havayolu şirketleri, gelirlerinde yaşanan keskin düşüşler nedeniyle faaliyetlerini devam ettirebilmek için birçok zorlu karar almak zorunda kaldılar. Bu kararlar arasında uçuş sayılarının azaltılması, personel sayısının azaltılması ve hatta bazı havayolu şirketlerinin iflas etmesi gibi önemli adımlar yer almaktadır. Ayrıca, yolcuların seyahat alışkanlıkları da önemli ölçüde değişti ve hava yolculuğuna olan talep düşüş gösterdi. Tüm bu faktörler, havacılık sektörünün krizle mücadele etmek için ciddi çaba sarf etmesine neden oldu (Bielecki vd., 2020).

COVID-19 krizinin havacılık sektörü üzerindeki etkileri oldukça büyük oldu ve sektörün geleceği belirsizliğini koruyor. Yatırımların azalması, siparişlerin iptali ve uçakların emekliye ayrılması, sektörün önümüzdeki dönemde de zorlu bir süreçten geçeceğini gösteriyor. Bununla birlikte, havayolu şirketleri müşteri ihtiyaçlarına uygun çözümler sunmak için çalışıyor ve kısa vadede karlı olan rotalarda operasyonlarını sürdürmeye devam ediyorlar. Havayolu sektörü, hükümetlerin sağlık ve seyahat kısıtlamalarına bağlı olarak birçok engelle karşı karşıya kalmıştır. Havayolu şirketleri, yolcuların güvenliğini ve sağlığını korumak için çeşitli önlemler almak zorunda kalmıştır. Bunlar, maske takma zorunluluğu, sosyal mesafe kuralları, uçuş öncesi COVID-19 testleri, uçakların düzenli olarak dezenfekte edilmesi gibi önlemlerdir. Kısacası, havacılık sektörü COVID-19 krizinin önemli bir etkisi altında kalmıştır ve sektörün geleceği hala belirsizdir. Ancak havayolu şirketleri, müşterilerin ihtiyaçlarına uygun çözümler sunmak ve kısa vadede karlı olan rotalarda operasyonlarını sürdürmek için çaba göstermektedir (Boston Consulting Group, 2020).

COVID-19 aşularının dağıtımı için havacılık sektörü hayati bir rol oynuyor. Çünkü aşuların büyük çoğunluğu yurt dışından tedarik ediliyor ve taşınması, soğuk zincir gereksinimleri gibi özel koşullar gerektiriyor. Ayrıca, aşuların hızlı bir şekilde tedarik edilmesi ve dağıtılması, pandemiden kurtulmak ve ekonomileri yeniden canlandırmak için önemlidir. Havayolları, bu aşuların güvenli ve zamanında teslim edilmesinde önemli bir rol oynayarak, dünya genelinde milyarlarca insanın hayatını kurtaracaklardır.

Bir hub havalimanı, çeşitli uçuş bağlantılarının işletilmesine olanak tanır ve bu şekilde, hedef varış noktasına ulaşmak için bir duraklamanın kaçınılmaz olduğu durumlarda yolculara uygun seyahat seçenekleri sunar. Bağlantı merkezlerinin bağlantı modeli, hem kısa hem de uzun mesafeli uçuşları birbirine bağlar ve sorunsuz geçiş prosedürünün garantisini olarak hizmet eder. Ancak, özellikle kriz zamanlarında havayolları için ek kısıtlamalara neden olabilecek havayolları için oldukça maliyetli bir yaklaşımdır (Combe ve Bréchemier, 2020). Uzun mesafeli uçuşlar ve duraklamalı uçuşlar, COVID-19 riskine maruz kalmaktan korkan yolcular arasında endişe yaratma eğilimindedir (McMahon, 2020).

Günümüzde, turistlerin tercihi, kesintisiz geziler yapmak yönünde değişti. Bu değişikliğin nedeni, koronavirüs bulaşma korkusu ve ülkelerin giderek karmaşıklaşan giriş düzenlemeleri olarak görülebilir. Bu durum, havayollarının rota ağlarını yeniden düzenlemeleri gerektiği anlamına gelmektedir. Havayolu şirketleri, istenilen sonuçları elde etmek için önemli adımlar atmaları gerekmektedir. Bunlar, yeni pazar pozisyonlarının belirlenmesi, daha yeni teknolojilerin uyarlanması ve daha verimli bilgi kullanımı gibi konuları içermektedir. (Bouwer vd., 2020).

Pandemi sürecinde, seyahat edenlerin güvenini geri kazandırmak için yapay zeka ihtiyacı arttı. Yapay zeka, insanları korumak ve sosyal mesafeyi sağlamak açısından önemli bir rol oynamaktadır. Bu amaca ulaşmak için uygun maliyetli modeller ve otomatikleştirilmiş operasyonlar sunulması beklenmektedir. Örneğin, yapay zeka, bir havalimanı terminalindeki kalabalık tahminlerini zaman çizelgesine göre yapmak için kullanışlı bir araçtır (Boyle, 2020).

Şirketlerin çevrimiçi toplantıların yaygınlaşması ile iş odaklı seyahatlere olan talepte düşüş bekleniyor. İş seyahatleri havayolu endüstrisi için önemli bir gelir kaynağıydı, ancak bu durum günümüzde önemli ölçüde azaldı (Wyman, 2020). Bu senaryo, havacılık sektörü için önemli müşterilerin ve gelirin kaybına neden olabilir. Uluslararası uçuşların yeniden başlaması için, belirli bir ülkeye giriş yapmak isteyen yolcular için tek tip kurallar oluşturulması gerekmektedir. Bu günlerde, havalimanı ve havayolu personeli yolcuların gerektirdiği belgeler konusunda sık sık karışıklık yaşamaktadır. Ayrıca, daha iyi yolcu veri yönetimi gerekmektedir.

Havacılık endüstrisi, nakit miktarının azalması nedeniyle iflas riski ile karşı karşıyadır ve bu da sektörde çalkantılı bir döneme neden olmaktadır. Bu dönemde havayolları, maliyetleri düşürerek ve büyük bir yeniden yapılanma



süreciyle hayatta kalmaya çalışıyorlar. Havayolları, talebi kontrol edemese de pandemi dönemlerinde maliyetleri azaltmak için fırsatlar aramalıdır. Rota ağı ve filo gibi unsurların karlılık açısından yeniden değerlendirilmesi ve yeniden yapılanma stratejileri geliştirilmesi, iflastan kaçınmak için hayati öneme sahiptir.

Havacılık endüstrisi pandemi sürecinde büyük bir sarsıntı yaşadı ve bu durum havayollarının performansını da etkiledi. Havayolları, düşük yolcu sayısı ve seyahat kısıtlamaları nedeniyle azalan talep nedeniyle düşük doluluk oranları ile karşı karşıya kaldılar. Ayrıca, uçuş rötarı ve iptaller de arttı, seyahat planlamalarını olumsuz yönde etkiledi. Bu durum, bazı havayollarının müşteri hizmetleri kalitesinin kötüleşmesine ve yolcuların memnuniyetinin azalmasına neden oldu. (Monmousseau vd., 2020).

### 3. DERİN ÖĞRENME

Derin öğrenme (deep learning), yapay sinir ağlarına dayalı bir makine öğrenmesi yöntemidir. Bu yöntem, özellikle büyük veri setlerinde ve karmaşık görevlerde başarıyla kullanılmaktadır. Ayrıca, görüntü işleme, doğal dil işleme, oyun oynama gibi birçok uygulama alanında da kullanılmaktadır. Derin öğrenmenin temelinde, çok katmanlı yapay sinir ağları yer alır. Bu ağlar, verileri işleyerek, öğrenme sürecinde, veriler arasındaki karmaşık ilişkileri bulmaya çalışırlar.

Derin öğrenme yöntemi, 1950'lerden bu yana araştırmacılar tarafından incelenmiş ve geliştirilmiştir. Ancak, son yıllarda özellikle büyük veri setleri ve geliştirilen yeni öğrenme algoritmaları sayesinde, derin öğrenme yöntemi daha da popüler hale gelmiştir. Bu popülerlik sayesinde, özellikle endüstriyel alanda birçok uygulama gerçekleştirilmiştir.

Derin öğrenme yöntemi, birçok farklı algoritma ve teknikle uygulanabilir. Bu algoritmaların bazıları şunlardır:

Yapay sinir ağları: Derin öğrenme yönteminin temelini oluşturan yapay sinir ağları, insan beyninin çalışma mantığına benzer bir şekilde, veriler arasındaki karmaşık ilişkileri öğrenirler.

Evrişimli sinir ağları (CNN): Görüntü işleme gibi uygulamalarda kullanılan bu algoritma, veri setindeki görüntülerin özelliklerini tespit ederek, nesne tanıma gibi görevleri gerçekleştirir.

Uzun-kısa süreli bellek (LSTM): Doğal dil işleme gibi uygulamalarda kullanılan bu algoritma, dilin yapısını anlayarak, metinleri analiz eder ve anlamsal ilişkileri tespit eder.

Otomatik kodlayıcılar (Autoencoders): Verilerin özneteliklerini çıkarmak için kullanılan bu algoritma, girdi verisini sıkıştırarak daha az boyutlu bir temsil elde eder.

Derin Q-öğrenme (Deep Q-Learning): Oyun oynama gibi uygulamalarda kullanılan bu algoritma, öğrenme sürecinde, ödül ve ceza gibi faktörleri dikkate alarak, en iyi stratejiyi bulmaya çalışır.

Derin öğrenme yöntemi, genellikle büyük veri setleri gerektirir. Bu nedenle, veri toplama ve veri önileme süreçleri oldukça önemlidir. Veri önileme sürecinde, verilerin temizlenmesi, özniteliklerinin belirlenmesi ve ölçeklendirilmesi gibi adımlar yer alır. Bu adımlar, öğrenme sürecinin başarısını etkileyen önemli faktörlerdir.

Derin öğrenme yöntemi, aynı zamanda, eğitim verilerinin yanıltıcı olabileceği bir risk de taşır. Bu riski azaltmak için, veri setleri genellikle eğitim, doğrulama ve test verileri olarak üçe ayrılır. Eğitim verileri, modelin öğrenmesi için kullanılırken, doğrulama verileri, modelin performansının izlenmesi için kullanılır. Test verileri ise, modelin gerçek dünya koşullarında nasıl performans gösterdiğini ölçmek için kullanılır.

Derin öğrenme yöntemi, ayrıca, yüksek hesaplama gücü gerektirdiği için, özellikle GPU gibi özel donanımların kullanılmasıyla daha hızlı çalışabilir. Ayrıca, derin öğrenme yöntemi, hiperparametrelerin belirlenmesi gibi birkaç zorluğa da sahiptir. Bu nedenle, derin öğrenme modelleri oluştururken, hiperparametreleri doğru bir şekilde ayarlamak çok önemlidir.

Sonuç olarak, derin öğrenme yöntemi, yapay zekâ alanında önemli bir yer edinmiş bir makine öğrenmesi yöntemidir. Özellikle, büyük veri setleri ve karmaşık görevlerde başarıyla kullanılabilir. Ancak, derin öğrenme yöntemi, doğru veri önileme, veri seti bölümlenmesi ve hiperparametre ayarı gibi faktörleri dikkate almadan uygulandığında, başarısız sonuçlar elde edilebilir.

## **4. HAVACILIK UÇUŞ VERİLERİNİN ANALİZİ**

### **4.1. Veri Kümesi**

Veri kümesinde 2010-2020 yılları arasında ülkemiz sınırları içerisinde gerçekleşen yurtiçi uçuşlar ve uçuş noktaları arasında yer alan yurtdışı kaynaklı uçuşlar bulunmaktadır. Veri seti kapsamında C# ile ayrı olarak geliştirilen bir konsol uygulaması yardımıyla gerçekleştirilen data cleaning aşamasından sonra 62597 satır sayısına sahip veri elde edilmiştir. Bu çalışmada elde edilen veri setinden yola çıkılarak uçuşlar, iptal ya da rötar/yönlendirme durumuna göre sınıflandırılmışlardır.

**Tablo 1. Havacılık Uçuş Veri Setinin Tablo ile Gösterimi**

Havacılık Uçuş Veri Seti	
Sınıf	Anonim
Kategori	Havacılık ve Uçuş Verileri
Alt Kategori	Uçuş Veri Seti

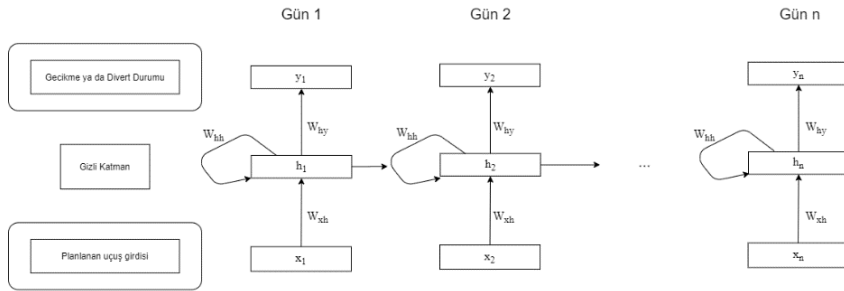
Veri Sağlayıcı	Devlet Hava Meydanları İşletmesi Genel Müdürlüğü
Açıklama	62597 Satır Sayısına Sahip Havacılık Uçuş Veri Seti
Format	CSV
Anahtar Kelimeler	Uçuş, Havalimanı, İptal, Rötar, Yönlendirme
İletişim Bilgileri	<a href="https://www.dhmi.gov.tr">https://www.dhmi.gov.tr</a>
Kayıt Sayısı	62597
Güncelleme	Mayıs 2020
TOPLAM BOYUT	4.6 MB

**Kaynak:** DHMİ

## 4.2. Derin Öğrenme ile Havacılık Uçuş Verilerinin İleriye Dönük Tahmini

Çalışmada, derin özyinelemeli sinir ağları (DÖSA) kullanılarak denetimli öğrenme modeli oluşturulmuştur. DÖSA mimarisi, önceki adımların çıktısının bir sonraki adımın çıktısını etkilediği iterasyonel bir yapıya sahiptir. Bu çalışmada kullanılan veri seti, DÖSA modeline uygun olduğu için bu mimari tercih edilmiştir. Yapay sinir ağı (YSA) modelleri tek katmanlı olduğu için kompleks modellere uygun değildir. Bu nedenle, geri beslemeli YSA tercih edilmiş ve gizli katmanlardaki nöron sayısı belirlenirken Karsoliya (2012) tarafından önerilen yöntemler kullanılmıştır. Modelde input ve output birimlerinin yanı sıra, derin öğrenme mimarilerinin temelini oluşturan birden fazla gizli katman bulunmaktadır.

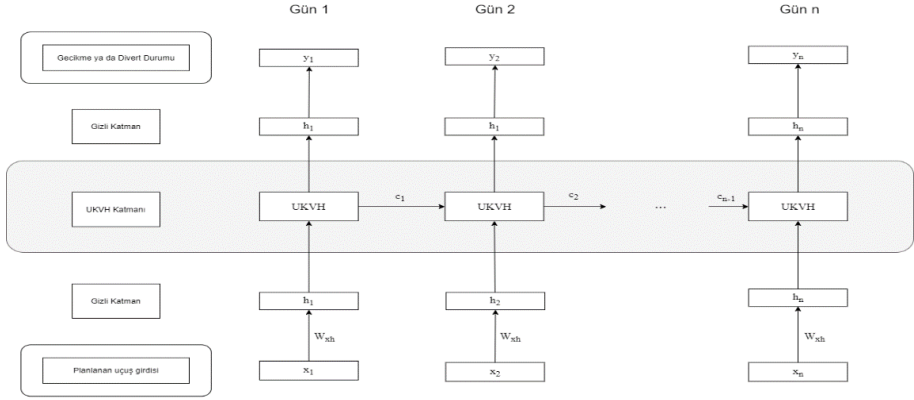
**Şekil 1. DÖSA ile Uçuş Tahminleme Modeli Diyagramı**



Yukarıdaki diyagramda  $W_{hh}$ , bir önceki adım ve bulunduğu adım üzerinde yer alan gizli katmanlar arasındaki geçiş için ağırlık matrisini,  $W_{xh}$ , giriş ve gizli katman arasındaki ağırlık matrisini ve  $W_{hy}$ , gizli katman ve çıkış

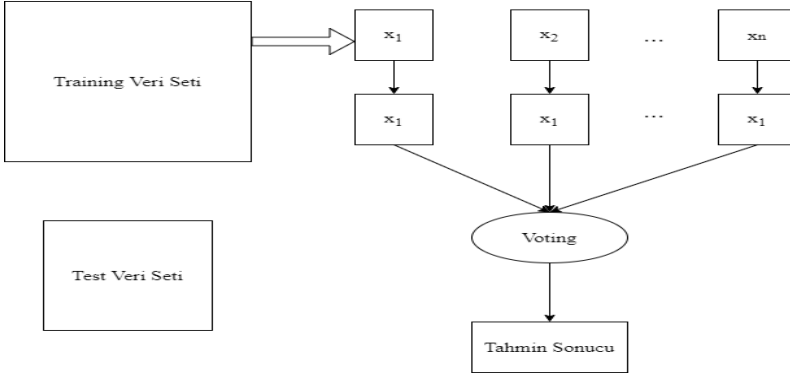
arasındaki ağırlık matrisine karşılık gelmektedir.  $x_t$  planlanan uçuş girdisi ile  $y_t$  çıkış katmanları arasında  $n$  sayıda  $h_t$  gizli katmanı bulunmaktadır. Bir önceki adımın sonucu bir sonrakine etki edecek şekilde yinelemeli olduğundan bu çalışmada kullanılan havacılık uçuş veri setine de uygun bir modeldir. Şekil 2’de UKVH ile uçuş tahminleme modeli diyagramı gösterilmiştir.

Şekil 2. UKVH ile Uçuş Tahminleme Modeli Diyagramı



Burada  $W_{hh}$ ,  $W_{xh}$  ve  $W_{hy}$  ifadeleri DÖSA modelinde açıklandığı gibi ağırlık matrislerine karşılık gelmektedir.  $x_t$  planlanan uçuş girdisi ve  $y_t$  çıkış katmanları arasında  $n$  sayıda  $h_t$  gizli katmanı ve UKVH katmanı bulunmaktadır.  $c_t$  bulunulan adımdaki hafıza değerini ifade etmekte olup  $c_{t-1}$  bir önceki adımın hafıza değerine karşılık gelmektedir. UKVH katmanında bir önceki adıma ait hafıza verileri tutulduğundan havacılık uçuş veri seti üzerinde uygulanmak üzere geliştirilen bu model başarıyı artırmaktadır. Şekil 3’te RF ile uçuş tahminleme modeli diyagramı gösterilmiştir.

Şekil 3. RF ile Uçuş Tahminleme Modeli



Yukarıdaki, RF ile uçuş tahminleme modelinin nasıl çalıştığı açıklanmaktadır. Bu model, önceki uçuş verilerini kullanarak en iyi tahmin sonucunu elde etmek için karşılaştırmalı bir yöntem kullanmaktadır. Ayrıca, modelin eğitiminde literatürde farklı yaklaşımlar olmasına rağmen, DÖSA modelinin en uygun ve etkili olduğu tespit edilmiştir. Bu nedenle, uzun kısa vadeli hafıza (UKVH) modeli tercih edilerek deneysel çalışmalar yapılmıştır. Bu çalışmalar sonucunda da UKVH modelinin daha iyi sonuçlar verdiği görülmüştür.

## 5. BULGULAR

Kullanılan veri kümesinin yaklaşık %75'lik bölümü rötar/yönlendirme olmuş uçuşlardan oluşurken %25'lik kısmı da iptal olan uçuşlardan oluşmaktadır. Buna göre %80 eğitim ve %20 test verisi olacak şekilde çapraz doğrulama uygulanarak iptal ya da rötar/yönlendirme olma durumuna göre modellenen DÖSA mimarisi eğitildiğinde, sınıflandırmadaki başarı oranı yaklaşık olarak %75 çıkmıştır. Yinelenen her adımda yaşanabilecek olan ezberlemeyi azaltmak için her gizli katmana dropout değerleri eklenmiştir.

Gizli katmanların bilgisini uzun vadede hafızada depolayabildiği için DÖSA'dan daha iyi performans gösteren UKVH modeli de uygulanarak sınıflandırmada yaklaşık %76 başarı elde edilmiştir.

Özniteliklerin mimariye öğretilerek sınıflandırma işlemlerinin gerçekleştirildiği bir makine öğrenmesi algoritması olan Random Forest (RF) ile çalışmanın asıl konusunu oluşturan derin öğrenme mimarilerinin uygulanmasından önce sınıflandırma yapılarak sonuç verileri elde edilmiştir. Buna göre RF yaklaşık %82 doğru sınıflandırma oranıyla UKVH metotundan büyük bir fark olmasa da daha başarılı olmuştur.

Derin öğrenme modelleri arasında yapılan karşılaştırmalı deneyler sonucunda, UKVH modelinin doğru sınıflandırma ve başarı oranı açısından en yüksek performansı gösterdiği tespit edilmiştir. Bu sonuç, Çizelge 2'de ayrıntılı olarak sunulmuştur ve diğer modellerin performansı ile


kıyaslanmıştır. Deney sonuçları, UKVH modelinin diğer modellere kıyasla daha etkili ve doğru olduğunu ortaya koymaktadır.

**Tablo 2. Parametrelere Göre Farklı Modeller Vasıtasıyla Hesaplanan Değerler**

Parametreler	Ölçüm Değerleri	RF	DÖSA	UKVH
IP_ROTAR_YONLENDIRME=Rötar /Yönlendirme	Doğruluk Değeri (%)	82.21	78.41	76.96
	Recall (%)	96.21	94.07	96.5
	Precision (%)	96.18	80.36	77.96
	F-score (%)	96.2	86.68	86.3
	ROC-AUC score	90.11	78.35	71.68


RF makine öğrenmesi algoritması kullanılarak yapılan sınıflandırmada, farklı tarih ve saatlerde Ankara Esenboğa Havalimanı ve İzmir Adnan Menderes Havalimanı arasında gerçekleşen uçuşlara ait tahminleme sonuçları Şekil 4 üzerinde gösterildiği gibi elde edilmiştir.

**Şekil 4. RF Algoritması Uygulanarak 2017 Yılına Ait Tahminlemeleri İçeren Grafik**



Yine aynı algoritma kullanılarak yapılan tahminleme işleminde bu sefer geleceğe dönük bir tahminleme işlemi gerçekleştirilmiştir. Kalkış ve varış noktaları aynı seçilmiştir.


**Şekil 5. RF Algoritması Uygulanarak 2021 Yılına Ait Tahminlemeleri İçeren Grafik**



RF algoritmasıyla elde edilen tahminleme değerlerine bakılacak olursa bulunulan ay, gün ve yıl değerlerinin sonuç yüzdelerinin belirlenmesinde etkili olduğu görülmektedir. RF makine öğrenmesi algoritmasını kullanarak farklı kalkış varış noktaları ve tarihler için yapılan tahminlemelerin sonuçları da EKLER başlığı altında sunulmuştur.


DÖSA derin öğrenme mimarisi kullanılarak yapılan tahminleme işleminde, yine kalkış olarak Ankara Esenboğa Havalimanı ve varış olarak İzmir Adnan Menderes Havalimanı seçilerek yapılan tahminleme işlemine ait sonuçlar Şekil 6 üzerinde gösterilmiştir.

**Şekil 6. DÖSA Mimarisi Uygulanarak 2017 Yılına Ait Tahminlemeleri İçeren Grafik**



Yine aynı mimari kullanılarak yapılan tahminleme işleminde bu sefer geleceğe dönük ve 2021 yılına ait tarihleri kapsayan bir tahminleme işlemi gerçekleştirilmiştir. Kalkış ve varış noktaları Ankara Esenboğa Havalimanı ve İzmir Adnan Menderes Havalimanı olarak seçilmiştir. Sonuçlara ait sütun grafiği aşağıda verilmiştir.

**Şekil 7. DÖSA Mimarisi Uygulanarak 2021 Yılına Ait Tahminlemeleri İçeren Grafik**



DÖSA derin öğrenme mimarisi kullanılarak katmanlarda 128-64-64-1 (input-hidden layer 1, hidden layer 2-output) nöron olacak şekilde model kurulumu yapılmıştır. Ara katmanlarda dropout kullanılarak ezberleme (overfitting) yapılmasının önüne geçilmeye çalışılmıştır. Aktivasyon fonksiyonu olarak input ve gizli katmanlarda denetimli yinelemeli modeller için iyi sonuç veren ReLU fonksiyonu kullanılmıştır. Output katmanındaki aktivasyon fonksiyonu ise sigmoid olarak belirlenmiş olup en iyi sonuç elde edilmeye çalışılmıştır. Model compile edilirken loss metodu olarak mse, optimizer adam, metric değeri olarak accuracy (doğruluk) seçilmiştir.

Bu çalışma kapsamında kurulan son model olan UKVH modelinde DÖSA modelinden farklı olarak hafıza hücresi yardımıyla bir önceki zamandan gelen bilgi bir sonrakine aktarılabilir. Burada farklı olarak veri ölçeğine bağımlılıktan dolayı 0-1 değerleri arasına ölçekleme işlemi yapılmıştır. Ancak daha sonra ters dönüşüm ile tekrar gerçek ölçeğe çevrilmiştir. Bir diğer farklı unsur olarak timestep değeri tanımlanmış olup, giriş verisinin büyüklüğü ayarlanmıştır. DÖSA modelinde olduğu gibi dropout parametresi kullanılarak sistemin aşırı ezberlemesinin önüne geçilmiştir. 128-64-1 nöron katman yapısı modele uygulanmıştır. Output katmanında aktivasyon fonksiyonu olarak yine sigmoid tercih edilmiştir.

## **Sonuç**

Bu araştırmanın sonuçlarına göre, havacılık endüstrisi ekonomik zorluklarla karşı karşıya olsa da doğru planlama ve stratejilerle bu zorlukların üstesinden gelebileceği ortaya çıkmaktadır. Finansal yönetim, devlet yardımı, yeni ortaklıklar ve maliyet tasarrufu gibi ekonomik stratejilerin yanı sıra, filo planlaması, sağlık önlemleri, yeni uçak tasarımları ve uygun bilet fiyatları da



endüstrinin ayakta kalmasına yardımcı olabilir. Ayrıca, kriz sonrası deneyimli personel ihtiyacının artmasıyla birlikte, personelin güçlendirilmesinin de havayolu işletmecileri için faydalı olacağı düşünülmektedir.

Bu hedefler doğrultusunda, öncelikle uçuş veri setini temizleme ve sayısallaştırarak inşa edilecek modellere uygun hale getirildikten sonra model mimarilerinin oluşturulması aşamasına geçilmiştir.

RF, DÖSA ve UKVH mimarileri, uçuş tahminleme modelinin geliştirilmesinde kullanılmıştır. RF modeli, tarih, saat, kalkış ve varış noktaları parametreleri kullanılarak tahminleme işlemi yapmak için bir yöntem kullanmıştır. DÖSA modelinde, aynı parametreler kullanılarak birden fazla gizli katmanlı yapay sinir ağı oluşturularak eğitilmiştir. UKVH modelinde ise hafıza hücresi kullanılarak bir önceki adıma ait bilgiler depolanarak sonuçlar elde edilmiştir. DÖSA modeli, sayısal olarak UKVH'den daha iyi sonuçlar vermiştir. Ancak, DÖSA ve UKVH arasında doğruluk oranı bakımından ayırt edici bir fark tespit edilmemiştir.

RF makine öğrenmesi algoritması doğru sınıflandırma bakımından daha iyi sonuç verse de çalışmanın odak noktasını oluşturan derin öğrenme modelleri üzerine yoğunlaşmıştır. Bu kapsamda, UKVH modeli DÖSA modeline kıyasla daha yüksek doğruluk değerine sahip olup, gelecekte yapılacak havacılık sektörünü ilgilendiren çalışmalarda da kullanılması bakımından örnek teşkil edecektir.

---

**Hakem Değerlendirmesi:** Dış Bağımsız

**Yazar Katkısı:** Zekeriya ŞAHİN %50, Ekrem SÜZEN %50

**Destek ve Teşekkür Beyanı:** Çalışma için destek alınmamıştır.

**Etik Onay:** Bu çalışma etik onay gerektiren herhangi bir insan veya hayvan araştırması içermemektedir.

**Çıkar Çatışması Beyanı:** Çalışma ile ilgili herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

**Peer Review:** Independent double-blind

**Author Contributions:** Zekeriya ŞAHİN %50, Ekrem SÜZEN %50

**Funding and Acknowledgement:** No support was received for the study.

**Ethics Approval:** This study does not contain any human or animal research that requires ethical approval.

**Conflict of Interest:** There is no conflict of interest with any institution or person related to the study.

---

## **Kaynakça**

- Abate, M., Christidis, P., Purwanto, A. J. (2020). COVID-19 Salgını sonrasında havayollarına devlet desteği. *Hava Ulaştırma Yönetimi Dergisi*, 89, 101931.
- Albers, S., Rundshagen, V. (2020). European Airlines'ın COVID-19 Salgınına stratejik yanıtları (Ocak-Mayıs, 2020). *Hava Ulaştırma Yönetimi Dergisi*, 87, 101863.
- Boston Consulting Group. (2021, 27 Nisan). Boston Consulting Group releases annual sustainability report, 5 Mart 2023 tarihinde <https://www.bcg.com/press/27april2021-boston-consulting-group-releases-annual-sustainability-report> adresinden erişilmiştir.
- Boyle, M. (2020). Decreased incidence of infections caused by pathogens transmitted commonly through food during the COVID-19 Pandemic, *Foodborne Diseases Active Surveillance Network, 10 U.S. Sites, 2017–2020*
- Belcastro L, Marozzo F, Talia D, Trunfio P. (2016), Using scalable data mining for predicting flight delays. *ACM Trans Intell SystTechnol.*, 8, 1–20.
- Belcastro L., Marozzo F., Talia D., Trunfio P. (2016), Using scalable data mining for predicting flight delays, *ACM Trans. Intell. Syst. Technol.*, 1, 5-20.
- Bielecki, M., Patel, D., (2020). Reprint of: Air travel and COVID-19 prevention in the pandemic and peri-pandemic period: A narrative review, *Travel Medicine and Infectious Disease*, Vol: 38
- Brouwer, E., Peeters, LM., (2020). COVID-19 in people with multiple sclerosis: A global data sharing initiative, *Multiple Sclerosis Journal*, V:26, 10.
- Budd, L., Ison, S., Adrienne, N. (2020). COVID-19 Pandemisine Avrupa havayolu müdahalesi- Havayolu işletmeciliği ve yönetimi için daralma, konsolidasyon ve gelecekteki hususlar. *Ulaştırma İşletmeciliği ve Yönetimi Araştırması*, 37, 100578.
- Choi S, Kim YJ, Briceno S, Mavris D., (2016). Makine öğrenimi algoritmalarına dayalı olarak hava kaynaklı hava yolu gecikmelerinin tahmini. In: *Proceeding of IEEE/AIAA 35th Dijital Aviyonik Sistemler Konferansı (DASC)*, 1–6.
- Combe, E., Bréchemier, D., (2020). Avant Le Covid-19 Le Transport Aérien En Europe : Un Secteur Déjà Fragilisé, Roland Berger, fondopol.
- Dube, E., Verger, P., Scronias, D., (2021). Attitudes of healthcare workers towards COVID-19 vaccination: a survey in France and French-speaking parts of Belgium and Canada, *ECDC*, Volume 26, Issue 3.
- Dunn, G., (2020). Koronavirüsün havayolları üzerindeki etkisinin sayılarla hikayesi. 8 Haziran 2020 tarihinde

- <https://www.flightglobal.com/strategy/how-the-airline-industryhas-been-hit-by-thecrisis/138554.article?adredir=1/41> adresinden erişilmiştir.
- EASA (2020), COVID-19 aviation health safety protocol, EASA, 2020d. 31 Mayıs 2020 tarihinde <https://www.easa.europa.eu/document-library/generalpublications/covid-19-aviation-healthsafety-protocol> adresinden erişilmiştir.
- Findlater, A., Bogoch, I. I. (2018). İnsan hareketliliği ve bulaşıcı hastalıkların küresel yayılımı: Hava yolculuğuna odaklanma. *Parazitolojide Eğilimler*, 34(9), 772-783.
- Grant Thornton, (2020). COVID-19 salgınının finansal raporlama etkileri, 5 Mart 2023 tarihinde <https://www.grantthornton.com.tr/enguncel/raporlar-ve-arastirmalar/covid-19-salgininin-finansal-raporlama-etkileri/?hubId=1673828> adresinden erişilmiştir.
- Hospitalitynet, (2021, 29 Aralık). The year in review - 2021 most read stories on hospitality net. 5 Mart 2023 tarihinde <https://www.hospitalitynet.org/news/4108197.html> adresinden erişilmiştir.
- Haghani, M., Bliemer, M.C., Goerlandt, F., & Li, J. (2020). Koronavirüsler, COVID-19 ve bununla ilişkili güvenlikle ilgili araştırma boyutları hakkında bilimsel literatür: Bilimsel bir analiz ve kapsam bütünlüme. *Güvenlik bilimi*, 129, 104806.
- IATA. (2020b.) Yıllık Değerlendirme Raporu. 02 Mayıs 2021 tarihinde <https://www.iata.org/contentassets/c81222d96c9a4e0bb4ff6ced0126f0bb/iata-annual-review-2020.pdf> adresinden erişilmiştir.
- IATA. (2020c). COVID-19'dan sonra havacılığın yeniden başlatılması, 3 Mart 2023 tarihinde <https://www.iata.org/contentassets/f1163430bba94512a583eb6d6b24aa56/covid-medical-evidence-for-stratejileri-200423.pdf> adresinden erişilmiştir.
- IATA. (2020e). IATA: Yolcu pazarı analizi. Uluslararası Hava Taşımacılığı Birliği, Montreal, Kanada. 3 Mart 2023 tarihinde <https://www.iata.org/en/iata-repository/publi-kasyonlar/ekonomik-raporlar/havayolları---ara-2019/> adresinden erişilmiştir.
- J. De Vos, (2020). COVID-19 ve müteakip sosyal mesafenin seyahat davranışı üzerindeki etkisi, *Transportasyon Research Interdisciplinary Perspectives*, 5, 100121. <https://doi.org/10.1016/j.trip.2020.100121>.
- Kang, L., Hansen, M., (2017). Behavioral analysis of airline scheduled block time adjustment, *Transp. Res. Part E: Log. Transp. Rev.* 103, 56–68.
- Karsoliya S., (2012), Approximating number of hidden layer neurons in multiple hidden layer bpn architecture, *International Journal of Engineering Trends and Technology*, 6, 714–717.

- Kenan, N., Jebali, A., Diabat, A., (2018). The integrated aircraft routing problem with optional flights and delay considerations. *Transp. Res. Part E: Log. Transp. Rev.*, 118, 355–375.
- Khatib, A. N., Carvalho, A.M., Primavesi, R., To, K., & Poirier, V. (2020). COVID-19 sırasında uçmanın risklerinde gezinmek: Güvenli hava yolculuğu için bir inceleme. *Seyahat Tıbbi Dergisi*, 27(8), taaa212.
- Kim YJ, Choi S, Briceno S, Mavris D., (2016), A deep learning approach to flight delay prediction. *Proceeding of EE/AIAA 35th Dijital Aviyonik Sistemler Konferansı (DASC)*, 1-6,
- Lamb, T. L., Winter, S. R., Rice, S., Ruskin, K. J., Vaughn, A. (2020). COVID-19 Salgını sırasında ve sonrasında yolcuların uçmaya istekli olduklarını tahmin eden faktörler. *Hava Ulaştırma Yönetimi Dergisi*, 89, 101897.
- Liu, J., Liao, X., Qian, S., Yuan, J., Wan g, F., Liu, Y., Zhang, Z. (2020). Şiddetli akut solunum sendromu Koronavirüsünün toplum bulaşması 2, Shenzhen, Çin, 2020. *Ortaya Çıkan Bulaşıcı Hastalıklar*, 26(6), 1320.
- Manna, S., Biswas, S., Kundu, R., Rakshit, S., Gupta, P., Barman, S., (2017), A statistical approach to predict flight delay using gradient boosted decision tree, *International Conference on Computational Intelligence in Data Science (ICCIDS 2017)*.
- McMahon DE, Peters GA, Ivers LC, Freeman EE (2020) Global resource shortages during COVID-19: Bad news for low-income countries. *PLoS Negl Trop Dis* 14(7).
- Monmousseau, P., Marzuoli, A., Feron, E., (2020). Impact of Covid-19 on passengers and airlines from passenger measurements: Managing customer satisfaction while putting the US Air Transportation System to sleep. *Transportation Research Interdisciplinary Perspectives*, V:7 .
- Prasad US, Chauhan PA, AshaL S. (2016), Data mining & predictive analysis on airlines performance. *Int J Pure Appl Math*.2018;118:1–12. *AIAA 35th Dijital Aviyonik Sistemler Konferansı (DASC); 2016*, 1–6.
- Sobieralski, J.B. (2020). COVID-19 ve havayolu istihdamı: Tarihsel belirsizlik şoklarından sektöre bakış. *Ulaştırma Araştırmaları Disiplinlerarası Bakış Açıları*, 5, 100123.
- Sternberg, A., Soares, J.D.A., Carvalho, D., Ogasawara, E., (2017). A review on flight delay prediction. *arXiv: Computers and Society*.
- Suau-Sanchez, P., Voltes-Dorta, A., Cugueró-Escofet, N. (2020). COVID-19'un bir ir taşımacılığı üzerindeki etkisinin erken bir değerlendirmesi: Sadece başka bir kriz mi yoksa bildiğimiz şekliyle havacılığın sonu mu?. *Ulaştırma Coğrafyası Dergisi*, 86, 102749.
- Thiagarajan B, Srinivasan L, Sharma AV, Sreekanthan D, Vijayaraghavan V. (2017), A machine learning approach for prediction of on time

- performance of flights., *Proceeding of 2017 IEEE/AIAA 35th Digital Avionics Systems Conference (DASC)*, 6.
- Türker, G. Ö. (2020). Covid-19 salgını turizm sektörünü nasıl etkiler? Turizm akademisyenleri perspektifinden bir değerlendirme. *Uluslararası Sosyal Bilimler ve Eğitim Araştırmaları Dergisi*, 6(2), 207-224.
- Wyman, J., Shah, P.B., Welt, F., (2020). Triage Considerations for Patients Referred for Structural Heart Disease Intervention During the COVID-19 Pandemic: An ACC/SCAI Position Statement, *JACC Journal*, Vol. 13 No. 12.
- Yazdi, A.A., Dutta, P., Steven, A.B., (2017). Airline baggage fees and flight delays: a floor wax and dessert topping? *Transp. Res. Part E: Log. Transp. Rev.*, 104, 83–96.
- Yu, B., Guo, Z., Asian, S., Wang, H., Chen, G., (2019), Flight delay prediction for commercial air transport: A deep learning approach, *Transportation Research Part E*, 125, 203–221.

### Extended Abstract

The COVID-19, which emerged in Wuhan, China in December 2019, has significantly affected almost every sector in today's world. COVID-19, declared as a pandemic by the World Health Organization, has also affected and continues to affect air transportation. As of 2020, various measures have been taken in air transportation by countries around the world. This situation has led to the social and economic impact of air transportation. COVID-19, the largest epidemic disease since the SARS outbreak, has led to human measures in civil aviation, such as the use of masks, social distancing rules, and the necessity of disinfectants. In addition, Türkiye, like other countries around the world, has been affected in terms of civil aviation. In this study, flight data before and after the COVID-19 period were analyzed.

According to the latest data released by the United States Transportation Department, 14.69% of all flights in 2020 experienced delays or cancellations for various reasons. Among these, 0.19% were attributed to diversions, which refer to landing at an airport different from the originally planned destination. Delays and cancellations have significant financial implications for airline companies and result in passenger dissatisfaction. As a response, many countries have implemented strict legal regulations and imposed financial penalties on airlines to compensate for the damages caused by such issues.

By using delay prediction systems developed for flights, it is possible to reduce costs caused by delays and save companies billions of dollars. Delay prediction systems with learning capabilities can predict delays in advance. The results of delay predictions can be shared in real-time with passengers, airports, and airlines to take necessary precautions and planning before the flight. This can also contribute significantly to risk planning. In this regard,

the Federal Aviation Administration (FAA) is working to reduce flight planning and delay costs (Belcastro et al., 2016).

The aviation industry has experienced a significant decline due to the COVID-19 pandemic, leading to many consequences. Firstly, capacity reductions and low demand increased pressure on the industry. This situation also had adverse effects on employment. Secondly, airline employees responsible for customer management were the most at risk. Thirdly, the pandemic led to unwanted results in continuing flights without passengers. Fourthly, while labor costs decreased, salaries of those employed in the sector and revenues from airlines decreased as well. Fifthly, COVID-19 has shown that it has a harmful effect on all the benefits that aviation jobs can bring to the entire economy. This situation has caused significant changes in aviation employment and caused a larger percentage of gross value added produced by each aviation employee to experience a loss (IATA, 2020).

The dataset contained domestic flights within the borders of Türkiye and international flights between flight destinations that took place between 2010 and 2020. After the data cleaning phase performed with a console application developed separately in C#, a dataset with 62597 rows was obtained. In this study, flights were classified according to their status as cancelled or delayed/re-routed, based on the obtained dataset.

Due to the impact of the coronavirus crisis and reduced flight schedules, airline fleets have been grounded for extended periods of time. This situation incurs additional costs, such as expenses associated with aircraft maintenance and parking fees (Adrienne et al., 2020). Airlines are currently grappling with the challenges posed by the industry during these difficult times, particularly in terms of finding suitable storage options for their aircraft. The decrease in flight demand caused by the COVID-19 pandemic has posed significant challenges for airlines, necessitating strategic adjustments to ensure their recovery and future survival (Cristina et al., 2020).

The aviation industry is currently confronted with the risk of bankruptcy as cash flow diminishes, leading to a turbulent period for the sector (Kikoyo et al., 2020). Airlines are making significant efforts to endure this challenging phase by implementing cost reduction measures and undergoing substantial restructuring. While airlines have limited control over demand, they should actively seek opportunities to minimize costs during periods of pandemics. It is essential for airlines to reassess aspects such as route networks and fleet operations from a profitability standpoint and devise effective restructuring strategies to avert bankruptcy (Kikoyo et al., 2020).

The aviation industry has experienced a significant disruption during the pandemic, affecting the performance of airlines. Airlines faced low load factors due to decreased demand caused by low passenger numbers and travel restrictions. Additionally, flight delays and cancellations increased, negatively impacting travel planning. This situation caused a decrease in customer

service quality and passenger satisfaction for some airlines (Monmousseau et al., 2020).

The findings indicated that the aviation industry can overcome economic challenges with proper planning and strategies, despite facing economic difficulties. Economic strategies such as financial management, government aid, new partnerships, and cost savings, as well as fleet planning, health measures, new aircraft designs, and appropriate ticket prices, can help the industry survive. In addition, it is believed that strengthening personnel will be beneficial for airline operators due to the increasing need for experienced staff after the crisis.

In line with these goals, after cleaning and digitizing the flight data set to make it suitable for the models to be built, the stage of creating model architectures was initiated. RF, DÖSA, and UKVH architectures were used in the development of the flight prediction model. The RF model used a method to make predictions using the parameters of date, time, departure, and arrival points. In the DÖSA model, multiple hidden-layer artificial neural networks were created and trained using the same parameters. In the UKVH model, information from the previous step was stored using memory cells to obtain results. The DÖSA model provided better results numerically than UKVH. However, no distinguishing difference was detected in terms of accuracy rate between DÖSA and UKVH.

Although the RF machine learning algorithm provides better results in terms of accurate classification, the focus of the study was on deep learning models. In this context, the UKVH model has a higher accuracy value compared to the DÖSA model and will serve as an example for future studies related to the aviation sector.