



Flight delay prediction with machine learning algorithms in airline disruption management

Nevra Yaman^{1*} , Ediz Atmaca² 

¹Directorate General of Civil Aviation, 06570, Maltepe, Ankara, Türkiye

²Department of Industrial Engineering, Faculty of Engineering, Gazi University, 06570, Maltepe, Ankara, Türkiye

Highlights:

- A tool for use in airline disruption management
- It is an example for help in decision making dynamic environment
- Use of machine learning techniques in airline scheduling

Keywords:

- Rescheduling of Flights
- Disruption Management
- Flight Delay Prediction
- Machine Learning

Article Info:

Research Article

Received: 05.11.2022

Accepted: 17.09.2023

DOI:

10.17341/gazimmfd.1199784

Correspondence:

Author: Nevra Yaman

e-mail:

nevrayaman@yahoo.com

phone: +90 536 344 5056

Graphical/Tabular Abstract

Management of unexpected events, which is the last stage of airline scheduling, has a very dynamic structure. This dynamic structure requires the effective use of available data in order to produce rapid solutions. For this purpose, machine learning techniques have been applied to analyze flight information and use it to help in decision making. In this paper, machine learning techniques were used to classify flights according to delay categories and find critical factors for minimizing delays. These classification methods are support vector machine, random forest, C 5.0, k-nearest neighbor and CART algorithms. An example for the comparing prediction success of these methods in finding the flights with the most delays (abnormal flights) are shown in Figure A. In the Figure A, the x-axis shows the amount of samples considered and the y-axis shows how many of them were predicted correctly. Additionally, the best possible prediction curve, apart from the algorithms used, is also shown in blue at the top. The red line in the middle indicates how much would be correct even if a random choice was made. As can be seen from Figure A, the 'Abnormal Delay' class was predicted most correctly in support vector machine (yellow curve) and random forest (green curve).

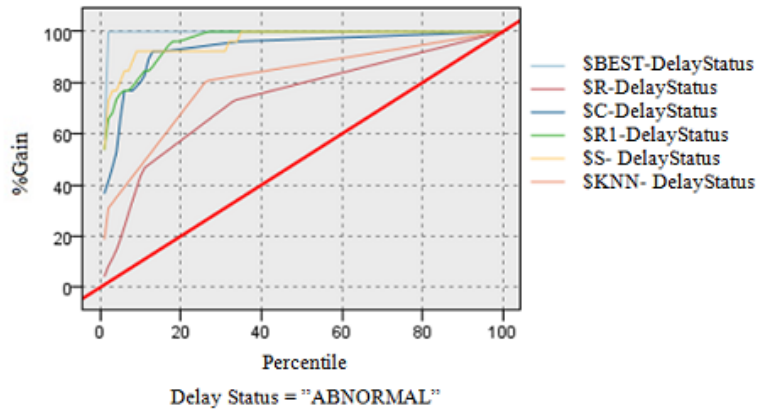


Figure A. Classification results for abnormal flights

Purpose: The purpose of this study is to classify flights according to their delays and find important delay factors in order to help the decision maker to produce quick solutions for disrupted flights in airline disruption management.

Theory and Methods: In the study, in there scheduling process related to flight disruptions; machine learning algorithms were used to determine the risk factors, to easily access meaningful data and to make a delay prediction for flights to help decisionmaking. For minimizing flight delays and helping decision maker to produce quick solutions, classification is considered and flights are classified according to their delay time.

Results: The aim of the study is to provide a preliminary idea about the flights to the decision-maker by ensuring that the flights are evaluated according to the delay classes. Accordingly, it has been seen that predicting the delay classes of flights will help the decision-maker in terms of providing new information on disruption management, which has been an important research topic in recent years. Then the use of different machine learning techniques for delay prediction has been studied.

Conclusions: Also, delay prediction is carried out in the literature in two different ways as robust scheduling and schedule recovery. It has been observed that it has a structure that carries the characteristics of both. For this reason, it is thought that accurate delay prediction will be beneficial to operators.



Havayolu bozulma yönetiminde gecikme tahmini için makine öğrenmesi algoritmaları ile sınıflandırma

Nevra Yaman^{1*}, Ediz Atmaca²

¹Sivil Havacılık Genel Müdürlüğü, 06570, Maltepe Ankara, Türkiye

²Gazi Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, 06570, Maltepe, Ankara, Türkiye

ÖNEÇIKANLAR

- Havayolu bozulma yönetiminde kullanılacak bir araç
- Dinamik ortamda karar vermede yardımcı olacak bir örnektir
- Havayolu çizelgelemede makine öğrenmesi tekniklerinin kullanımı

Makale Bilgileri

Araştırma Makalesi

Geliş: 05.11.2022

Kabul: 17.09.2023

DOI:

10.17341/gazimmfd.1199784

Anahtar Kelimeler:

Yeniden uçuş çizelgeleme,
bozulma yönetimi,
uçuş gecikme tahmini,
makine öğrenmesi

ÖZ

Son yıllarda havacılık sektöründe artan rekabet ile birlikte havayolu şirketleri operasyonlarını daha verimli şekilde yönetmeye yönelmişlerdir. Havayolunda çizelgeleme faaliyetleri uçuş çizelgeleme, uçak çizelgeleme, ekip çizelgeleme ve beklenmedik olayların yönetimi olarak dört aşamada gerçekleştirilmektedir. İlk üç aşamada, sistem için uygulanabilir bir uçuş çizelgesi meydana getirilmekte ve son aşamada ise uçuşların gerçekleşmesi esnasında ortaya çıkan aksaklıklara çözüm aranmaktadır. Havayolu şirketleri uçuşlarda ortaya çıkan aksaklıklarda ciddi bir zaman kaybı ve maliyet limiti ile karşılaşmaktadır. Uçuş aksaklıkları yönetiminin en zor tarafı, uzun dönemler boyunca geliştirilen planların dakikalarla ifade edilebilecek bir süre içerisinde yeniden çizelgenmesi zorunluluğudur. Uçuş aksaklıkları ortaya çıktığında, yeniden çizelgeleme durumunda, şirketlerin geleneksel yöntemlere, sezgilere ya da deneyime dayalı kararlar vermeleri ve operasyonlardaki ayrıntıların fazlalığı kararı olumsuz yönde etkilemektedir. Yapılan çalışmada, havayolu şirketinde uçuş aksaklıkları ile alakalı yeniden çizelgeleme sürecinde; risk faktörlerini belirlemek, anlamlı veriye kolayca ulaşmak ve karar vermeye yardımcı olmak üzere uçuşlar için gecikme tahmini yapılması amacıyla makine öğrenmesi algoritmaları kullanılmıştır. Makine öğrenmesinin, geçmiş verilerden anlamlı yeni bilgiler çıkararak yeniden çizelgeleme konusunda karar vericiye destek olması sağlanmış ve sınıflandırma algoritmaları ile uçuş gecikmeleri tahmin edilmiştir. Böylece, uçuşlar izlenirken hem gerçekleşen hem de gerçekleşme ihtimali olan gecikmelerin önceden görülerek gerekli önlemlerin alınabilmesi sağlanmıştır.

Flight delay prediction with machine learning algorithms in airline disruption management

HIGHLIGHTS

- A tool for use in airline disruption management
- It is an example for help in decision making dynamic environment
- Use of machine learning techniques in airline scheduling

Article Info

Research Article

Received: 05.11.2022

Accepted: 17.09.2023

DOI:

10.17341/gazimmfd.1199784

Keywords:

Rescheduling of flights,
disruption management,
flight delay prediction,
machine learning

ABSTRACT

With the increasing competition in the aviation industry in recent years, airline companies have tended to manage their operations more efficiently. Airline scheduling activities are carried out in four stages as flight scheduling, air craft scheduling, crew scheduling and disruption management. In the first three stages, a feasible flight schedule is created for the system, and in the last stage, solutions are sought for the problems that arise during the flight. Airline companies face a serious loss of time and cost constraints in flight disruptions. The most difficult aspect of flight disruption management is the necessity of rescheduling the plans in minutes. When flight disruptions occur, in the case of rescheduling, companies make decisions based on traditional methods, in tuition or experience, and the excess of details in operations negatively affects the decision. In the study, in their scheduling process related to flight disruptions; machine learning algorithms were used to determine the risk factors, to easily access meaningful data and to make a delay prediction for flights to help decisionmaking. Machine learning has provided support to the decision maker in rescheduling by extracting meaningful new information from the current data, and flight delays have been predicted with classification algorithms.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *nevrayaman@yahoo.com, hediz@gazi.edu.tr / Tel: +90 536 344 5056

1. Giriş (Introduction)

Havayolu çizelgeleme süreci; havayolunun planlama ve operasyonlarının başlangıç noktası olan uçuş çizelgeleme süreci ile başlamaktadır. Bu aşamada, kalkış-iniş çiftleri ile mümkün bir uçuş şebekesinin oluşturulmasıyla ilgilenilmekte olup uçuş zamanları ve uçuş sıklıkları belirlenmektedir. Daha sonra, uçak çizelgeleme sürecinde, havayolu şirketinin bir tarife dönemi boyunca uygulayacağı uçuş çizelgesi ortaya çıktıktan sonra daha kısa bir planlama dönemi içerisinde uçuş dizisindeki uçuşlara uçak tipi atanmakta ve her bir uçağın uçaacağı rota belirlenmektedir. Bu sürecin sonunda da, ekip çizelgeleme süreci ile her uçak tipinde uçacak ekip niteliği, personel sayısı ve her bir personelin uçaacağı uçuşlar belirlenmektedir. Son olarak ise, operasyon kontrol merkezlerinde uçuştan 72 saat önce uçuşların izlenmeye başlandığı, gerektiğinde değişiklik ve düzeltmelerin yapıldığı süreç gerçekleştirilmektedir. Bu aşamada, beklenmeyen olaylar yaşanabilmekte olduğu için mevcut çizelge uygulanamaz hale gelmekte ve birtakım değişiklikler yapılması ihtiyacı ortaya çıkmaktadır. Sonradan gelişen bu yeniden çizelgeleme sürecinde de doğru ve hızlı karar verebilmek için etkin veri kullanımı, saklı bilgiye ulaşabilmek bir gereklilik haline gelmiştir.

Uçak, ekip ve yolcular havayollarının önemli kaynakları arasında yer almaktadır. Bununla birlikte, günümüzde bilgi her işletme için en önemli kaynak haline gelmiştir. Uçuş, uçak ve ekip çizelgelemelerinin hepsi, havayolu planlama aşamasında önceden oluşturulmaktadır. Ancak, çizelgelerin uygulanması sırasında; uçak arızası, personel değişikliği, hava şartları, havalimanı şartları gibi çeşitli aksamlar meydana gelebilmektedir. Bu noktada da, çizelgeyi düzeltmek için çeşitli yöntemlere ihtiyaç duyulmaktadır. Yeniden çizelgelemeden başka, çizelge bozulmalarına karşın; güçlü çizelgeleme olarak adlandırılan ve en başta çizelge hazırlanırken çizelgeye çeşitli esneklikler kazandırılarak bu bozulmalardan kaçınmaya çalışmak bir diğer yöntemdir. Bu çalışmada ise, çizelge uygulanmakta iken, henüz bir bozulma gerçekleşmemiş olsa bile gerçekleşme ihtimaline karşı hazırlıklı olabilmek ve hızlı karar alabilmek üzere uçuşlara ait gecikme tahmini yapılması için makine öğrenmesi kullanılmıştır. Sonuçta, yeniden uygulanabilir bir çizelge ortaya çıktığından bu çalışmanın hem güçlü çizelgeleme hem de çizelge düzeltme süreçlerinin özelliklerini taşıdığı düşünülmektedir.

Geçmiş verilerin yardımıyla gizli kalmış, fark edilmeyen bilgiye ulaşarak yapılan çıkarımlar, karşılaşılan yeni durumlar için karar vermede önemli bir rol oynamaktadır. Bu çalışmanın da konularından birini oluşturan makine öğrenmesi, 1950'li yıllarda kullanılmaya başlamış, girdi verisine göre kuralları çıkarıp öğrenen ve bilinmeyen verileri keşfetmek için bunları kullanan algoritmalarından oluşmaktadır.

Murphy [1]'de verilen tanımına göre makine öğrenmesi, gelecek veriyi tahmin etmek ya da belirsizlik altında karar verebilmek için mevcut veriyi otomatik olarak algılayan yöntemlerin bir kümesidir.

Makine öğrenmesi algoritmaları, denetimli, denetimsiz, yarı denetimli ve destekli öğrenen algoritmalar olmak üzere dörde ayrılmaktadır. Denetimli öğrenme algoritmalarında, öğrenme için kullanılacak bir eğitim seti bulunmakta ve çıkarılan kurallar yeni veriye uygulanmaktadır. Denetimsiz öğrenmede, eğitim seti yoktur ve veriye direkt uygulanmaktadır. Algoritma hem öğrenip hem de uygulamaktadır. Yarı denetimli algoritmalar da, kayıp verilerin olduğu durumlarda kullanılan ve kalanlar içinden öğrenmenin gerçekleştiği algoritmalarlardır. Destekli algoritmalar ise, dışarıdan geri bildirim olarak öğrenen algoritmalarlardır. Burada da, mevcut veri seti

eğitim ve test verisi olarak bölünerek eğitim gerçekleştirildiği için denetimli öğrenmeden bahsetmek mümkündür [2].

Bertolini vd. [3], makine öğrenmenin, bilgisayar bilimi ve çok değişkenli istatistik alanlarını içerdiği söylemiştir. Yapılan çalışmada, makine öğrenmesi için ayrıntılı bir literatür araştırması gerçekleştirilmiş; sinir ağları, destek vektör makinesi ve karar ağaçlarının öne çıkan makine öğrenmesi algoritmaları olduğu belirtilmiştir.

Bu çalışmada, uçuş gecikmelerini minimize edebilmek amacıyla, sınıflandırma yaparak öncelikle gecikmeleri tahmin etmek üzere makine öğrenmesi tekniklerine başvurulmuştur. Sınıflandırma ile nesnel özelliklerine göre önceden belirlenmiş sınıflardan birine atanmaktadır. Verilmiş bir veri setinde, verinin özellikleri ve bir özellik olarak her bir verinin ait olduğu sınıf yer almaktadır. Burada, diğer tüm özelliklerin bir fonksiyonu olarak, veri setinin eğitim kümesiyle veri sınıfının modeli bulunmakta ve test veri seti ile modelin performansı değerlendirilmektedir. Literatürde de çokça adı geçen ve burada ele alınan probleme uygun olduğu düşünülerek kullanılan makine öğrenme algoritmaları aşağıda sıralanmıştır:

- Karar Ağacı Algoritmaları: Tek bir düğümler başlamakta ve belli kriterlere göre bölünme işlemi devam etmektedir.
 - C5.0 Algoritması: Karar ağacı algoritmalarının anlaşılması ve yorumlanmasının kolay olması ile birlikte C5.0 algoritması büyük veri setlerinde oldukça yaygın bir kullanıma sahiptir.
 - C&RT Algoritması: Hem sayısal hem de nominal veri türlerini, girdi ve kestirimsel değişken olarak kabul edebilen C&RT algoritmasının, sınıflandırma ve regresyon problemlerinde çözüm olarak kullanılabilir bir algoritma olduğu söylenmektedir [4].
- Rastgele Orman: Rastgele Orman algoritması, topluluk öğrenme algoritmalarından biridir. Birden fazla karar ağacı üreterek sınıflandırma yapar ve böylece sınıflandırma başarısını yükseltmeye çalışır. Hem veriye hem de özelliklere göre karar ağacı üretilmekte ve en iyi sonuç alınmaktadır.
- Destek Vektör Makinesi: Destek vektör makineleri ile sınıfları birbirinden ayıran düzlem bulunmaya çalışılmakta ve bunu yapabilen birden fazla düzlem bulunabilmektedir. Bu noktada da en iyi sınıflandırmanın yapılabilmesi için, bu sınıflar arasındaki uzaklığın maksimize edilmesi ve uzaklık maksimize edilirken yanlış grupta kalan eleman sayısının minimize edilmesi istenmektedir.
- K En Yakın Komşu Algoritması: Bu algoritmada, ilk olarak k parametresi belirlenir. Bu parametre verilen bir noktaya en yakın komşuların sayısıdır. Örnek veri setine katılacak olan yeni verinin, mevcut verilere göre uzaklığı tek tek hesaplanır. İlgili uzaklık fonksiyonları yardımıyla ilgili uzaklıklardan en yakın k komşu ele alınmaktadır. Yeni veri, öznitelik değerlerine en yakına göre k. komşu veya komşuların sınıfına atanmaktadır. Seçilen sınıf, tahmin edilmesi beklenen gözlem değerinin sınıfı olarak kabul edilmektedir [5].

Sonraki bölümde, havayolu bozulma yönetimi, gecikme tahmini ve makine öğrenmesi ile ilgili literatürde yapılmış olan çalışmalardan bahsedilmiştir. 3. bölümde ele alınan problem tanımlanmış, 4. bölümde gerçekleştirilen uygulama ile elde edilen sonuçlar verilmiştir. 5. bölümde ise, ele alınan konu ve sonuçlar için genel bir değerlendirme yapılmıştır.

2. Literatür Araştırması (Literature Review)

Havayollarındaki dinamik yapı ve mevcut çizelgede meydana gelen bozulmalardan 1980'li yıllarda bahsedilmeye başlanmıştır. 1990'lı yıllarda ise operasyon kontrol merkezinde karar vermeye yardımcı olacak sistemlere ihtiyaç duyulduğu belirtilmiştir. Bununla birlikte,

havayolu çizelgeleme ve bozulma yönetimi ile ilgili matematiksel modelleme ve sezgisel yöntemleri içeren çok sayıda çalışma yapılmıştır.

Uçuş gecikmelerinin tahmin edilmesinin literatürde önemli bir çalışma konusunu oluşturduğu görülmüştür. Uçuş gecikme tahmini için veri madenciliği, istatistiksel yöntemler, optimizasyon yöntemleri, makine öğrenmesi gibi birçok teknığe başvurulmuştur.

Aldelghany vd. [6], havayolu operasyonlarının tam zamanında gerçekleşmesinin, müşteri memnuniyetinin sağlanması ve yenilerinin kazanılması konusunda anahtar faktör olduğu söylemiştir. Çalışmada, uçuş gecikmeleri ve gelecekte karşılaşılabilecek düzensizliklere karşı ikazları içeren ve en kısa yol algoritmasını temel alan bir model geliştirilerek bir operasyon kontrol merkezinde uygulanmıştır.

Kohl vd. [7], havayollarında bozulma yönetimini incelemiş ve OCC (Operasyon Kontrol Merkezi)'de çok kaynaklı karar destek sistemi için ilk örnek olacak bir çalışma gerçekleştirdiklerini söylemişlerdir. Çalışmada, bozulma yönetiminin çizelgede beklenmeyen bir değişiklik meydana geldiğinde yapılacakları belirlerken, ileri etkili çizelgeleme ile ilk başta bu değişikliklerden kaçınacak bir çizelge hazırlandığı belirtilmiştir.

Assent vd. [8], güçlü bir uçuş çizelgeleme yapabilmek için veri madenciliğini önermişlerdir. Çalışmada, havaalanı operasyonlarının çizelgenmesinde, uçuş varışlarındaki belirsizliğin önemli bir sorun olduğu söylenmiş ve ileri etkili bir çizelgeleme yapmak için uçuşların gecikme kategorilerine göre sınıflandırılması önerilmiştir. Uçuşların gecikmesine neden olan birçok özellik bulunmuş ve bunlar baskın olan uçuş gecikmeleri altında toplanmış ve karar ağaçlarının geniş çapta sınıf etiketlerini tahmin etmede başarılı bir şekilde uygulandığı söylenmiştir.

Serrano vd. [9], OCC'de farklı birimlerden gelecek (ekip, bakım...gibi) bilgilere de ihtiyaç olduğu ve etkili bir bozulma yönetimi sisteminin de, meydana gelebilecek beklenmeyen olayları tahmin edebileceği söylemiştir. Yolcu merkezli bozulma yönetimi için bir çalışma gerçekleştirilmiş ve uzun dönemde OCC'de verilen kararların yolcular üzerindeki etkisinden bahsedilmiştir. Diğer birimlerle entegre, çok modelli bir operasyon kontrol merkezinin bozulmaları yönetmede yardımcı olacağı söylenmiştir.

Havayollarında beklenmeyen olaylar sonucu yaşanan uçuş gecikmelerinin; iniş ya da kalkış zamanları, havaalanı, meydana gelen gecikmenin sonraki uçuşlara yayılması, havayolu, hava taşıma sistemi, slot tahsisi gibi birçok açıdan önemi bulunmaktadır [10]. Literatürdeki çalışmalarda da, bu gecikme nedenlerinden biri ya da birkaçı ele alınarak çalışmalar gerçekleştirilmiştir.

Rebollo vd. [11], kalkış gecikmelerini tahmin etmek üzere sınıflandırma ve regresyon modellerini kullanmışlardır. Çalışmada, gecikmeler tahmin edilerek eşik değerin altında kalıp kalmamasına göre sınıflandırılmıştır. Bunun için; lojistik regresyon, doğrusal regresyon, sinir ağı, sınıflandırma ağaçları, rastgele orman kullanılmış ve rastgele orman algoritmasının en iyi sonucu verdiği söylenmiştir. Rastgele orman algoritmasının, değişkenlerin önem derecelerini de otomatik ürettiği için iyi bir performans sağlandığı da belirtilmiştir.

Belcastro vd. [12], hava durumundan kaynaklanan uçuş gecikmelerini tahmin etmek için rastgele orman algoritmasını kullanmışlar ve iyi bir doğruluk elde edildiğini söylemişlerdir. Ariyawansa vd. [13], akıllı havaalanı sistemlerinde veri madenciliği ve makine öğrenmesi tekniklerini inceleyen bir çalışma gerçekleştirmişlerdir. Burada havaalanı performansının iyileştirilmesinin zincirdeki tüm bileşenlere bağlı olduğu belirtilmiş ve bunlardan biri olan uçuş gecikme tahmininde kullanılan tekniklere yer verilmiştir. Regresyon, destek

vektör makinesi, rastgele orman, bayes teorisi yaklaşımları, k-en yakın komşu yöntemleriyle uygulama gerçekleştirilmiştir. Sternberg vd. [14], uçuş gecikmelerinin havayolunun önemli bir performans göstergesi olduğunu söylemiş ve uçuş gecikme tahminini konusunda literatür araştırması gerçekleştirmişlerdir. Uçuş gecikmeleri ile ilgili çalışmaları; kök gecikme (gecikmenin yaşandığı ilk uçuş), gecikmenin yayılımı ve uçuşun iptali olmak üzere 3 bölümde incelemişlerdir. Bu çalışmada, uçuş gecikmelerinin tahmini probleminde makine öğrenmesi yöntemlerinin kullanımının giderek arttığı söylenmiştir. Bu tekniklerden de k-en yakın komşu, sinir ağları, destek vektör makinesi, bulanık mantık ve rastgele ormanın en çok kullanılanlar olduğu belirtilmiştir.

Achenbach vd. [15], kısa mesafeli uçuşlarda varış zamanı tahmini ve maliyet indeks optimizasyonu için tahmin edici makine öğrenme yöntemlerini kullanmışlardır. Yazarlar birçok algoritma ile deneme yaptıklarını ancak 'boosting' algoritması ve lineer regresyon ile en iyi sonuçları elde ettiklerini söylemişlerdir. Bu nedenle, bu iki algoritmayı birleştirerek kullanmışlardır. Maliyet indeksinin, varış zamanı tahminine entegrasyonu ile en iyi maliyet indeksinin bulunacağı belirtilmiştir.

Yu vd. [16], uçuş gecikmelerinin; çizelge optimizasyonu, havaalanı kapasitesi ve yer seçimi, uçuş değişiklikleri ve iptali gibi pek çok açıdan ele alındığını söylemiştir. Bu çalışmada, uçuş gecikme tahmini için veri bazlı bir model önerilmiştir. Modelde, makine öğrenmesinde DBN -*deeplearning network*- olarak adlandırılan ve birçok gizli katmandan oluşan bir yapay sinir ağı ve destek vektör regresyonu kullanılmıştır.

Lambelho vd. [17], bir havaalanında slot tahsisine destek olması amacıyla gecikecek ya da iptal olacak uçuşları tahmin etmek üzere makine öğrenmesi yaklaşımı geliştirmiştir. Stratejik fazda (6 ay önceden) hava koşulları nedeniyle gecikecek ya da iptal olacak uçuşları tahmin eden sınıflandırma algoritmaları önerilmiştir.

Khan vd. [18], karar vermedeki belirsizlikten kaçınmak için uçuşların kalkış zamanları ve sürelerini tahmin etmek üzere entegre makine öğrenmesi modeli önermişlerdir. Bu çalışmada; sinir ağları, destek vektör makinesi, rastgele orman gibi birçok makine öğrenmesi tekniği birlikte kullanılmıştır.

Bao vd. [19], geniş bir şebekede kalkış ve varış zamanlarını tahmin etmek üzere derin öğrenmeli sinir ağı önermişlerdir. Bu çalışmanın, uçuş gecikme tahmininde derin öğrenme için ilk basamak olduğu söylenmiştir.

Guo vd. [20], uçuş kalkış gecikme tahmini için rastgele orman regresyonu ve maksimum bilgi katsayısı yöntemlerini kombine eden bir yaklaşım önermişlerdir. Sonuçların; lineer regresyon, standart rastgele orman regresyonu, k-en yakın komşu ve yapay sinir ağları ile karşılaştırıldığında daha iyi olduğu söylenmiştir.

Shao vd. [21], uçuş kalkış gecikmelerini tahmin etmek üzere, havaalanı durumsal farkındalık haritasını -*uçak, hava durumu, havayolu çizelgesi gibi özellikler*- kullanan bir derin öğrenme yapısı önermişlerdir. Önerilen yapıda; destek vektör makinesi, çok katmanlı sinir ağı ve karar ağacı kullanılmıştır.

Uçuş gecikmelerinin tahmin edilmesinde; makine öğrenmesi tekniklerinin kullanıldığı çalışmalar Tablo 1'de özetlenmiştir. Tablo 1'de de görüldüğü gibi, günümüze doğru gelindiğinde; veri yönetimi ve uçuş gecikme tahmini ile ilgili çalışmaların arttığı görülmektedir. Bu çalışmada da, anlamlı ve faydalı bilgiye ulaşarak havayolu bozulma yönetiminde karar vericiye yardımcı olmak ve hız kazandırmak için makine öğrenmesi tekniklerinden yararlanılmıştır.

Uçuşların gecikme sınıfları ve gecikmelere neden olan önemli değişkenlerin belirlenmesiyle gecikmeleri büyük ölçüde engelleyecek önlemlerin alınabileceği düşünülmüştür.

3. Problemin Tanımı (Problem Definition)

Çizelgeleme sürecinde meydana getirilen uçuş çizelgesinin, uygulanma esnasında karşılaşılan ve önceden kestirelemeyen aksaklıklar sonucu çizelge düzeltme faaliyetlerine ihtiyaç duyulmaktadır. Böylece, mümkün olan en kısa süre içerisinde en doğru karar verilerek çizelgeye yeniden işleyiş kazandırmak; müşteri memnuniyeti ve karlılık açısından oldukça büyük bir öneme sahiptir. Bu hızlı karar verme sürecinde de, geçmiş verilerden yararlanarak gizli kalmış ya da gözden kaçabilecek bilgilerin sunulması, yeniden çizelgelemeyi kolaylaştıracaktır.

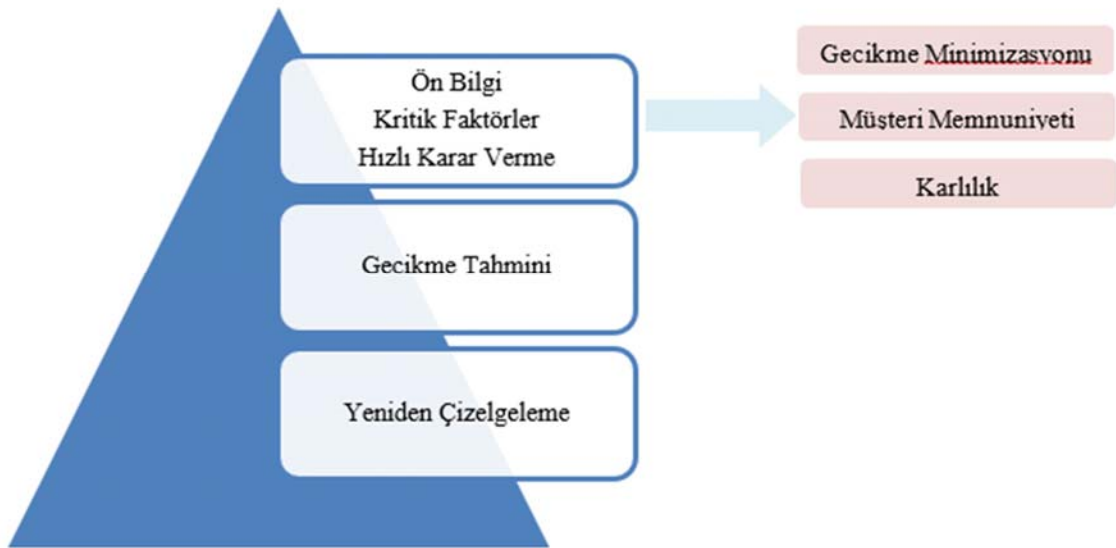
Mevcut durumda; geçmiş verilere göre, bilgi üreten bir yapının olmadığı görülmüştür. Günümüzde ise, geçmiş verinin analizi ve gelecek için çıkarımlar yapmak üzere kullanılması sistemler için oldukça faydalı hale gelmiştir. Bu çalışmada da; karar verici için

önemli faktörlere dikkat çekerek, yapılacaklarla ilgili ön bilgi sağlayan ve böylece hız kazandıran bir yapı oluşturulabilmesi için uçuşlara ait gecikme tahmini yapılmıştır. Gerçekleştirilen çalışma ve böylece sağlanması hedeflenen fayda Şekil 1’de gösterilmiştir. Şekil 1’de de görüldüğü gibi, yeniden çizelgeleme ile sistemin akışının olabildiğince hızlı devam edebilmesi gerekmektedir. Bununla birlikte, havayolu işletmelerinin başlıca amaçları olan karlılık, kaynak kullanımı ve müşteri memnuniyetinin maksimize edilmesi için uçuşlarda yaşanan gecikmelerin minimize edilmesi istenmekte, bu nedenle de operasyon kontrol merkezinde gerçekleştirilen çizelge düzeltme faaliyetleri önem kazanmaktadır. Bu çalışmada da, yeniden çizelgeleme yaparken karar vericiye uçuşlarla ilgili ön fikir sağlamak ve kritik faktörlere dikkat çekmek, böylece hız kazandırmak amacıyla uçuşlar için gecikme tahmini yapılmıştır. Önerilen yapı Şekil 1’de de gösterilmiştir.

4. Uygulama: Gecikme Tahmini (Application: Delay Prediction)

Tablo 1. Gecikme tahmininde kullanılan makine öğrenme algoritmaları (Machine learning algorithms used in delay prediction)

Çalışma	Konu	Yöntem
Assent ve diğerleri (2009), Rebollo ve Balakrishnan (2014)	Gecikme sınıfı tahmini Kalkış gecikmelerini tahmini	Karar ağaçları Lojistik regresyon, doğrusal regresyon, sinir ağı, sınıflandırma ağaçları, rastgele orman
Ariyawansa ve Aponso (2016)	Uçuş gecikme tahmini	Regresyon, destek vektör makinesi, rastgele orman, bayes teorisi yaklaşımları, k en yakın komşu
Belcastro ve diğerleri (2016) Achenbach ve Spinler (2018)	Uçuş gecikme tahmini Varış zamanı tahmini	Rastgele orman 'boosting' algoritması ve lineer regresyon
Yu ve diğerleri (2019)	Uçuş gecikme tahmini	Yapay sinir ağı ve destek vektör regresyonu
Lambelho ve diğerleri (2020) Guo ve diğerleri (2021)	Uçuş gecikmesi ya da iptalinin tahmini Kalkış gecikme tahmini	Rastgele orman regresyonu ve maksimum bilgi katsayısı
Khan ve diğerleri (2021)	Kalkış zamanı tahmini	Sinir ağları, destek vektör makinesi, rastgele orman
Bao ve diğerleri (2021) Shao ve diğerleri (2022)	Kalkış ve varış zamanları tahmini Kalkış gecikme tahmini	Derin öğrenmeli sinir ağı Derin öğrenme yapısı



Şekil 1. Yeniden çizelgelemede gecikme tahmini (Delay prediction in rescheduling)

Uçuşların sınıflandırılması için, ülkemizde faaliyet gösteren bir havayolunun 2018 yılına ait 1529 uçuşu ele alınmıştır. Bu uçuşlar, haftanın farklı günlerinde farklı havaalanlarında gerçekleşmiştir. Söz konusu havayolunun yalnızca yurtiçi uçuşları dikkate alınmıştır. Ülkemizdeki tüm havaalanlarından da uçuş sayısı toplam sayının içerisinde önemsenmeyecek kadar az olan 5 tanesi çıkarılmış, 33 havaalanına ait uçuşlar incelenmiştir. Excel’de oluşturulan veri seti 1530x52 boyutunda bir matris olup ilk satır başlıkları içermektedir. Tablo 2’de veri setine ait bir bölüm verilmiştir.

Tablo 2’ye göre; veri setinde her bir satır bir uçuşu göstermektedir. Sütunlarda ise uçuşların özelliklerini göstermek üzere; uçuşun çağrı adı, uçuşun haftanın hangi günü gerçekleştiği, tarih, kalkış ve varış havaalanı, her bir havaalanı, gecikme nedenleri ve ait olduğu gecikme sınıfı bilgileri yer almaktadır.

Literatürde de, uçuş gününün periyodik gecikme faktörü olarak değerlendirildiği görülmüştür. Örneğin; Cuma günleri trafik yoğunluğunun artması bazı aksaklık ve gecikmelere neden olabilmektedir.

Tablo 2’de görüldüğü gibi, *kalkış yeri* ve *varış yeri* özelliklerinde, havaalanlarına havacılıkta kullanılan kısaltmalarıyla yer verilmiştir. Aynı şekilde, *DOF (Date of Flight)* özelliği de tarihlerin havacılıkta kullanılan göstergesidir. Burada, uçuşların kalkış ve varış yeri özelliklerinin yanında her bir havaalanına da özellik olarak yer verilmesinin nedeni; bir gecikme sebebi olarak *kalkış ve varış yeri* başlıklarının yanında, her bir havaalanının etkisinin ayrıca görülmek istenmesidir.

Aynı şekilde, uçuşun gerçekleştiği gün ve *DOF* özelliklerine ayrı ayrı yer verilmiştir. Uçuş günü ve havaalanlarının her biri için de, o uçuşa ait olup olmama durumunu gösteren *T (Doğru)* ya da *F (Yanlış)* göstergeleri kullanılmıştır. Örneğin; 3 numaralı satırda yer alan uçuş Salı günü Ankara’dan İzmir’e gerçekleşmiştir.

Sütunlarda yer alan bu özelliklerin devamında gecikmeye neden olan faktörler bulunmaktadır. Havayolları tarafından belirlenen gecikmelere sebep olan faktörlerin büyük çoğunluğunu, hava trafik akış yönetimi, kalkış ve varış meydanlarına ait kısıtlar ya da olanaklar, yer hizmetleri, teknik, planlama, hava durumu, ekip, akaryakıt hizmetleri, uçuş planı aksaklıkları gibi nedenler oluşturmaktadır.

Verinin boyutu açısından, bu nedenlerden istatistiksel olarak en çok karşılaşılanları ve gecikme süresi olarak en fazla gecikmeye sahip olan 7 tanesi ele alınmıştır. Bunlar aşağıdaki gibidir ve bu özelliklerin değeri de *Evet* ya da *Hayır* olacak şekilde kullanılmıştır:

- Kalkış Meydanı Şartları
- Varış Meydanı Şartları

- Arıza ve Teknik Problemler
- Hava Durumu
- Ekip Aksaklıkları
- Yer Hizmetlerinden kaynaklanan aksaklıklar
- Diğer Nedenler

Uçuşlara ait son özellik ise; *gecikme sınıfı* bilgisi olmuştur. Gerçekleşmiş olan bu uçuşlar; planlanan uçuş saatine göre ne kadar geciktiği belirlenerek gecikme sınıfına atanmıştır. Gecikme süresi, planlanan kalkış zamanı ile gerçek kalkış zamanı arasındaki farka eşittir. Her uçuş için bu fark bulunduktan sonra uçuşların gecikme sınıfı belirlenmiş ve bir diğer özellik olarak veriye eklenmiştir. Gecikme sınıflarının oluşturulmasında, sektörden elde edilen bilgiler ve [18,22] dikkate alınmıştır. Buna göre belirlenen 5 gecikme sınıfı aşağıdaki gibidir:

1. 0-30 dakika arası: Gecikme Yok (1)
2. $30 < \text{gecikme süresi} \leq 45$: Az Gecikmeli (2)
3. $45 < \text{gecikme süresi} \leq 60$: Çok Gecikmeli (3)
4. $60 < \text{gecikme süresi} \leq 90$: Çok Fazla Gecikmeli (4)
5. Gecikme süresi > 90 : Normal Dışı Gecikme (5)

Aşağıda, ele alınan uçuşlar *gecikme sınıfı* sayılarına göre verilmiştir:

	Uçuş Sayıları
Gecikme Yok	1005
Az Gecikmeli	293
Çok Gecikmeli	133
Çok Fazla Gecikmeli	72
Normal Dışı	26

Excel’de hazırlanan uçuş tablosu IBM SPSS Modeller programında C5.0, Sınıflandırma ve Regresyon Ağaçları (C&RT), Rastgele Orman (RO), Destek Vektör Makinesi (DVM) ve k En Yakın Komşu (KNN) algoritmaları kullanılarak uygulanmıştır. Bu algoritmalar ile gerçekleştirilen uygulamada, veri seti ikiye ayrılmıştır. Verinin 2/3’ü eğitim verisi ve 1/3’ü test verisi olarak kullanılmıştır. Bu ayırma işleminde kullanılan programın rastgele seçin yapması sağlanmıştır. Verinin ilk bölümü, kullanılan algoritmaların eğitim verisi olarak model oluşturulmasında; ikinci bölümü ise test verisi olarak, oluşturulan modelin değerlendirilmesinde kullanılmıştır.

4.1. Algoritma Sonuçları (Results of Algorithm)

Kullanılan algoritmaların performansları, doğruluk dereceleri hesaplanarak değerlendirilmiştir. Tahmin edilecek sınıf sayısının 2’den fazla olması nedeniyle; algoritmaların karşılaştırılmasında ROC eğrisi (sınıf sayısı iki olduğunda kullanılan ve yöntemlerin performansını değerlendirmede başvurulan eğri) kullanılamamış ve programın bir çıktısı olarak elde edilen ‘Gains’ grafikleriyle

Tablo 2. Örnek Veri Seti (Data Set Example)

Çağrı	Pazartesi	Salı	Çarşamba	Perşembe	Cuma	Cumartesi	Pazar	Kalkış Yeri	Varış Yeri
1	T	F	F	F	F	F	F	LTAC	LTBJ
2	F	T	F	F	F	F	F	LTAC	LTBJ
3	F	F	T	F	F	F	F	LTAC	LTBJ
4	F	F	F	T	F	F	F	LTAC	LTBJ
5	F	F	F	F	T	F	F	LTAC	LTBJ
6	F	F	F	F	F	T	F	LTAC	LTBJ
7	F	F	F	F	F	F	T	LTAC	LTBJ
8	F	F	F	T	F	F	F	LTAC	LTFJ
9	F	F	F	F	T	F	F	LTAC	LTFJ
10	T	F	F	F	F	F	F	LTAC	LTFJ

karşılaştırma yapılmıştır. Doğruluk derecesi; elde edilen doğru sonuçların tüm veri sayısına oranlanmasıyla elde edilmektedir. Buna göre; Tablo 3'te algoritmaların doğruluk dereceleri verilmiştir.

Tablo 3. Algoritmaların Doğruluk Dereceleri
(Accuracy Degrees of Algorithms)

Algoritma	Doğruluk Derecesi
DVM	0,940
Rastgele Orman	0,934
C5.0	0,900
KNN	0,882
C&RT	0,864

Tablo 3'te de görüldüğü gibi, kullanılan algoritmaların doğruluk dereceleri arasında çok büyük farklar olmamakla birlikte, en yüksek doğruluk derecesine destek vektör makinesi ile ulaşılmıştır. Ayrıca, rastgele orman algoritması ile elde edilen doğruluk derecesi de destek vektör makinesine oldukça yakındır.

Algoritmalarla göre, gecikmeye etkisi açısından en önemli değişkenler de Tablo 4'te sıralanmıştır.

Tablo 4'e bakıldığında; tüm algoritmalarda 'KalkisMeydani' değişkeninin en önemli gecikme sebebi olduğu görülmektedir. Burada, kalkış meydanı olanakları ile ilgili sorunlarla hem sıklık hem de toplam süre açısından en çok karşılaşıldığı düşünülmüştür. Daha sonra ise, uçuş gecikmelerine en çok sebep olan nedenlerin algoritmaya göre sıralaması değişse de; uçak arızası, hava durumu, ekip sorunları, yer hizmetlerinden kaynaklanan sorunlar ve diğer

başlığı altında toplanmış -güvenlik, yeme/içme, akaryakıt hizmetleri, uçuş planı aksaklıkları gibi çeşitli nedenler- olduğu görülmektedir. Bununla birlikte, C5.0 ve KNN algoritmalarında Sivas Havalimanı ile Sabiha Gökçen Havalimanı; C&RT ve Destek Vektör Makinesinde Hatay Havalimanı; KNN ve Destek Vektör Makinesinde Balıkesir Havalimanı, C5.0 ve C&RT algoritmalarında Çorlu Havalimanı olmak üzere ortak bulgulara rastlanmaktadır. Ayrıca 'Cumartesi' ve 'Pazartesi' günleri gerçekleşen uçuşlar da karşılaşılan gecikmeler nedeniyle öne çıkmıştır.

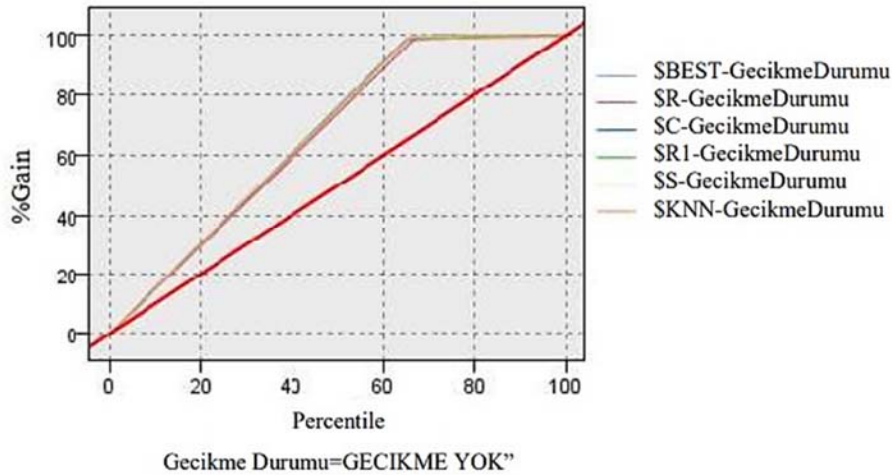
'Gains' grafikleri, algoritmaların değerlendirilmesinde her bir gecikme sınıfı için veri setindeki yüzdelik bölümlere göre doğruyu yakalama oranını göstermektedir. Bu grafikler; Şekil 2, Şekil 3, Şekil 4, Şekil 5 ve son olarak Şekil 6'da verilmiştir. Bu grafikler aracılığı ile, modellerin belirli sınıfları ne kadar iyi tahmin ettiğini ölçüp karşılaştırmaktadır.

Gains grafiğinde, x eksenine ele alınan örnek miktarını ve y eksenine ise bunların ne kadarının doğru tahmin edildiğini göstermektedir. Ayrıca, kullanılan algoritmaların dışında, mümkün olan en iyi tahmin eğrisi de mavi ile gösterilmiştir. Ortadaki kırmızı doğru ise, rasgele bir seçim yapılsa da ne kadarının doğru olacağını ifade etmektedir. Şekil 2'den de anlaşılacağı gibi 'Gecikme Yok' sınıfı tüm algoritmalarda neredeyse tam olarak doğru tahmin edilmiştir. Ayrıca, her bir algoritma için ortaya çıkan eğri birbirine çok yakın olduğu için hepsi üst üste gelmiştir.

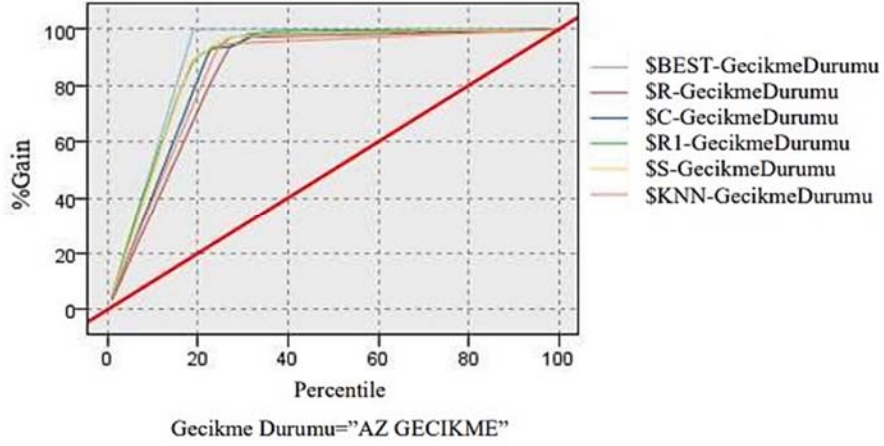
Şekil 3'e bakıldığında da, 'Gecikme Yok' durumunda olduğu gibi tüm algoritmalar birbirine yakın sonuçlar üretmiş ve üst üste gelmiştir.

Tablo 4. Değişkenlerin Önem Sıralaması (Order of Value Importances)

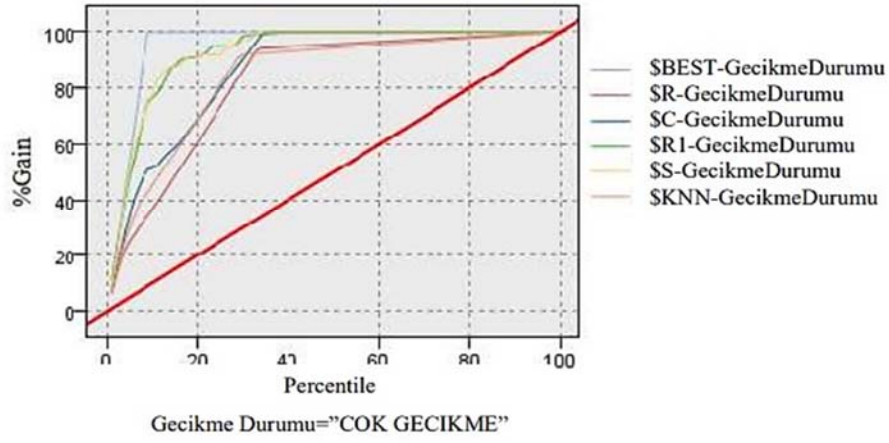
C5.0	C&RT	Rastgele Orman	KNN	DVM
KalkisMeydani	KalkisMeydani	KalkisMeydani	KalkisMeydani	KalkisMeydani
ArizaTeknik	ArizaTeknik	Diğer	Diğer	ArizaTeknik
HavaDurumu	Diğer	ArizaTeknik	HavaDurumu	HavaDurumu
Ekip	HavaDurumu	YerHizmetleri	ArizaTeknik	Diğer
Diğer	LTAY	HavaDurumu	YerHizmetleri	Ekip
YerHizmetleri	LTBU	DOF	Ekip	DOF
LTFJ	KalkisYeri	Ekip	LTAR	KalkisYeri
LTAR	LTDA	Cumartesi	VarisMeydani	LTFD
LTBU	YerHizmetleri	LTFJ	LTFD	VarisYeri
Cumartesi	-	Pazartesi	LTBS	LTDA



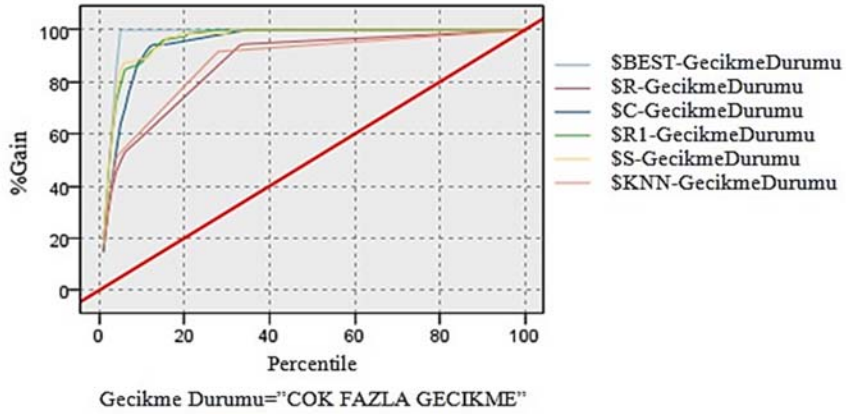
Şekil 2. 'GECIKME YOK' Sınıfı için Gains Grafiği (Gains Graphic of 'No Delay')



Şekil 3. 'AZ GECIKME' Sınıfı için Gains Grafiği (GainsGraphic of 'LittleDelay')

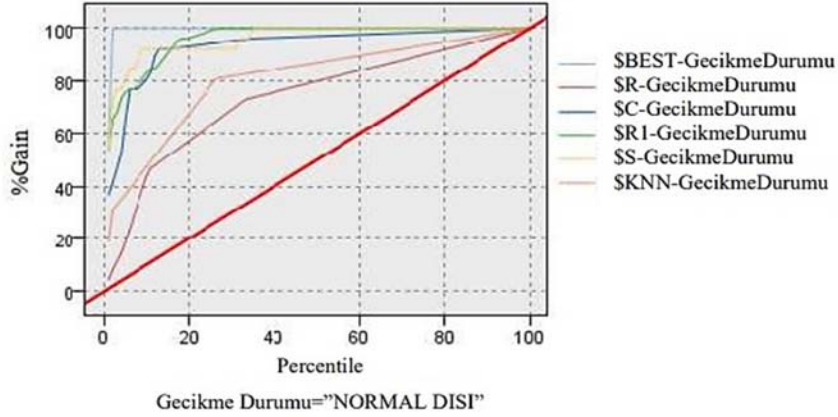


Şekil 4. 'COK GECIKME' Sınıfı için Gains Grafiği (GainsGraphic of 'TooDelay')



Şekil 5. 'COK FAZLA GECIKME' Sınıfı için Gains Grafiği (GainsGraphic of 'TooMuchDelay')

Tüm algoritmalar, en iyi tahmin durumunu gösteren mavi eğriden biraz ayrılmıştır.



Şekil 6. 'NORMAL DISI' Sınıfı için Gains Grafiği (GainsGraphic of 'AbnormalDelay')

Şekil 4'e bakıldığında ise, algoritmalar arasında farklılıkların başladığı görülmektedir. En iyi tahmin eğrisine en yakın sarı ve yeşil eğriler olmakla birlikte bu eğriler birbirlerine de çok yakındır. 'ÇOK GECİKME' sınıfı için Rastgele orman ve Destek Vektör Makinesinin en iyi sonucu verdiği görülmektedir.

Şekil 5'te görüldüğü gibi, 'ÇOK FAZLA GECİKME' sınıfı tahmininde ise; rastgele orman, destek vektör makinesi ve C5.0 birbirine yaklaşmış durumdadır. C&RT ve KNN algoritmaları ise birbirine yakın ve diğer algoritmalarından ve olabilecek en iyi tahminden uzak durumdadır.

'Normal Dışı' gecikme sınıfını tahmin ederken algoritmaların performanslarına bakılacak olursa; 'Çok Fazla Gecikme' sınıfı grafiğine benzeyen bir gains grafiği elde edildiği görülmektedir. C5.0, destek vektör makinesi ve rastgele orman birbirine yakın görünmekle birlikte rastgele orman algoritması diğer algoritmaların üstünde yer almıştır. Ayrıca KNN algoritmasına yakın olsa da, C&RT algoritması diğerlerinden büyük bir farkla ayrılmaktadır.

Gecikmelerin minimize edilebilmesi için uçşların gecikme sınıflarının tahmin edilmesi istendiğine göre ve 'normal dışı' gecikme sınıfının doğru tahmin edilmesi çok önemli olduğuna göre rastgele orman ve destek vektör makinesi algoritmalarının daha öne geçtiği düşünülmektedir.

Aynı bakış açısıyla, bir diğer önemli gecikme sınıfı 'çok fazla gecikme' için ise öne çıkan algoritmalar; C5.0 ve destek vektör makinesi olmuştur. 'Çok gecikme' gecikme sınıfı için de, 'normal dışı' gecikme sınıfında olduğu gibi destek vektör makinesi ve rastgele orman algoritmaları gerçeğe en yakın tahmin sonuçlarını elde etmiştir.

Rastgele orman algoritmasının, değişkenlere göre de karar ağacı oluşturması ve önemli değişkenleri belirtmesi bu algoritmanın kullanılmasında önemli bir belirleyici olmuştur. Destek vektör makinesi de, istatistiksel öğrenme metodlarını kullanan ve günümüzde oldukça yaygın kullanılan bir makine öğrenmesi algoritmasıdır. Normal dışı, çok fazla gecikmeli ve çok gecikmeli uçşların bulunmasının daha önemli olduğu bu çalışmada da; Destek Vektör Makinesi ve Rastgele Orman algoritmalarının öne çıktığı görülmektedir. Gecikme süresinin fazla olabileceği uçşlara dikkat çekilmesinin sağlanmasıyla; gerekli önlemler alınabilecek ve gecikmeler azaltılabilecektir.

5. Sonuçlar (Conclusions)

Mevcut çizelgenin bozulması durumunda; uçşları değiştirme, uçşları iptal etme, uygun olan başka uçşlar kullanma, uçşları geciktirme gibi yollarla çizelgeyi uygulanabilir hale getirmek için çözüm aranmaktadır. Bu çalışmada da, uçşların geciktirilmesinin önüne geçmek üzere uçşların gecikme sınıflarına göre değerlendirilmesi sağlanarak karar vericiye uçşlarla ilgili ön fikir verilmesi düşünülmüştür. Havayolu bozulma yönetiminde, meydana gelebilecek istenmeyen olaylardan mümkün olduğunca az etkilenilmesi istendiğinden riskli uçşların önceden bilinmesi ve buna göre hızlı karar alabilmek sisteme büyük kazançlar sağlayacaktır.

Öncelikle, literatürde havayolu bozulma yönetimi ve bu işlemlerin gerçekleştirildiği operasyon kontrol merkezine yönelik olarak yapılan çalışmalar incelenmiştir. Buna göre, uçşların gecikme sınıflarının tahmin edilmesinin, son yıllarda önemli bir araştırma konusu olan bozulma yönetimi konusunda karar vericiye yeni bir bilgi sunması açısından yardımcı olacağı görülmüştür. Bununla birlikte, farklı makine öğrenmesi tekniklerinin gecikme tahmini konusunda kullanımı sağlanmıştır.

Buna göre mevcut sistemde; geçmiş verilere göre, bilgi üreten bir yapının olmadığı görülmüştür. Günümüzde ise, geçmiş verinin analizi ve gelecek için çıkarımlar yapmak üzere kullanılması sistemler için oldukça faydalı hale gelmiştir. Karar vericilerin karşı karşıya kaldığı yoğunluk ve zorluklar da düşünülerek ortaya çıkan hızlı karar verme ihtiyacına yönelik olarak, uçşlara ait geçmiş verilerden yararlanılmasının, çizelge düzeltme faaliyetlerinde karar vericiye yardımcı olacağı görülmüş ve bu nedenle uçşlar için gecikme tahmini yapılmıştır. Bununla birlikte, sisteme gecikme olduktan sonra müdahale edilmesi yerine, gecikme tahminlerinden yararlanılarak gecikme yaşanmadan bunun engellenebilmesinin mümkün olabileceği düşünülmektedir.

Literatürde incelenen birçok çalışmada da, gecikme tahmini konusunun ele alındığı görülmüştür. Çizelge düzeltme ve gecikme minimizasyonunun etkin bir şekilde sağlanabilmesi için pek çok çalışmada meydana gelebilecek gecikmeler ile ilgili tahmin yapılması havayolları açısından da güncelliğini korumaktadır. Bu amaç için, makine öğrenmesi konusunda destek vektör makinesi ve rastgele orman algoritmalarının çokça kullanıldığı ve iyi sonuçlar elde edildiği görülmüştür. Tüm bu çalışmalara ek olarak, burada elde edilen sonuçlar göz önüne alındığında; daha sonra yapılacak çalışmalarda da, bu iki yöntemin kullanımının artarak devam edeceği düşünülmektedir.

Havayollarında bozulma yönetiminin giderek önem kazandığı ve yapılan çalışmaların arttığı görülmekte ve bu çalışmanın da makine

öğrenmesi tekniklerini kullanması açısından uçuş gecikme tahmini konusunda bir katkı sağlayacağı düşünülmektedir. Ayrıca gecikme tahmininin, literatürde ileri etkili çizelgeleme ve çizelge düzeltme olarak iki ayrı şekilde gerçekleştirilen havayolu bozulma yönetimi faaliyetlerinin her ikisinin özelliklerini de taşıyan bir yapıya sahip olduğu görülmüş ve bu çalışmanın da her iki konuda da değerlendirilebileceği düşünülmüştür. Bu nedenle, gecikme tahmini yapılması ve sonuçların değerlendirilerek kullanılması işleticiler açısından büyük fayda sağlayacaktır.

Kaynaklar (References)

- Murphy K.P., Machine Learning A Probabilistic Perspective, The MIT Press Cambridge, Massachusetts, 2012.
- Portugal I., Alencar P., Cowan D., The use of machine learning algorithms in recommender systems: A systematic review, Expert Systems With Applications, 97, 205-227, 2018.
- Bertolini M., Mezzogori D., Neroni M., Zammori F., Machine Learning for industrial applications: A comprehensive literature review, Expert Systems With Applications, 175, 114820, 2021.
- Yakut E., Veri madenciliği tekniklerinden C5.0 algoritması ve destek vektör makineleri ile yapay sinir ağlarının sınıflandırma başarılarının karşılaştırılması: imalat sektöründe bir uygulama, Doktora Tezi, Atatürk Üniversitesi Sosyal Bilimler Enstitüsü, 2012.
- Ülgen, K. Makine Öğrenimi Bölüm-5 (Karar Ağaçları), <http://medium.com/@k.ulgen90/makine-ogrenimi-bolum-5-karar-agacları-c90bd7593010>, Yayın Tarihi: 12.11.2017, Erişim Tarihi: 30.11.2022.
- Abdelghany K.F., Shah S.S., Raina S., Abdelghany A.F., A model for projecting flight delays during irregular operation conditions, Journal of Air Transport Management, 10 (6), 385-394, 2004.
- Kohl N., Larsen A., Larsen J., Ross A., Tiourine S., Airline disruption management—Perspectives, Experiences and Outlook, Journal of Air Transport Management, 13, 149-162, 2007.
- Assent I, Krieger R., Welter P., Herbers J., Seidl T., Data Mining For Robust Flight Scheduling, ResearchGate, 267-282, 2009.
- Serrano F.J.J., Kazda A., Airline disruption management: yesterday, today and tomorrow, Transportation Research Procedia, 28, 3-10, 2017.
- Carvalho L., Sternberg A., Gonçalves L.M., Cruz A. B., Soares L.A., Brandão D., On the relevance of data science for flight delay research: A systematic review, Transport Reviews, 41 (4), 499-528, 2020.
- Rebollo J. J., Balakrishnan H., Characterization and Prediction of Air Traffic Delays, Transportation Research Part C: Emerging Technologies, 44, 231-241, 2014.
- Belcastro L., Marozzo F., Talia D., Trunfio P., Using scalable data mining for predicting flight delays. ACM Transactions on Intelligent Systems and Technology, 8 (1), A1-A20, 2016.
- Ariyawansa C., Aponso A., Review on state of art data mining and machine learning techniques for intelligent airport systems, In Proceedings of 2016 International Conference on Information Management, ICIM, 134-138, 2016.
- Carvalho L., Sternberg A., Gonçalves L.M., Cruz A. B., Soares L.A., Brandão D., On the relevance of data science for flight delay research: a systematic review. Transport Reviews, 41 (4), 499-528, 2020.
- Achenbach A., Spinler S., Prescriptive analytics in airline operations: Arrival time prediction and cost index optimization for short-haul flights, Operations Research Perspectives, 5, 265-279, 2018.
- Yu B., Guo Z., Asian S., Wang H., Chen G., Flight delay prediction for commercial air transport: A deep learning approach, Transportation Research Part E, 125, 203-221 2019.
- Lambelho M., Mitici M., Pickup S., Marsden A., Assessing strategic flight schedules at an airport using machine learning-based flight delay and cancellation predictions, Journal of Air Transport Management, 82, 101737 2020.
- Khan W.A., Ma H., Chung S., Wen X., Hierarchical integrated machine learning model for predicting flight departure delays and duration in series, Transportation Research Part C, 129, 103225, 2021.
- Bao J., Yang Z., Zeng W., Graph to sequence learning with attention mechanism for network-wide multi-step-ahead flight delay prediction, Transportation Research Part C, 130, 103323 2021.
- Guo Z., Yu B., Hao M., Wang W., Jiang Y., Zong F., A novel hybrid method for flight departure delay prediction using random forest regression and maximal information coefficient, Aerospace Science and Technology, 116, 106822, 2021.
- Shao W., Prabowo A., Zhao S., Koniusz P., Salim F.D., Predicting flight delay with spatio-temporal trajectory convolutional network and airport situational awareness map, Neurocomputing, 472, 280-293 2022.
- Akıncılar A., A New Approach For Robust Scheduling In Airline Scheduling Problems: Robust Aircraft Routing, PhD Thesis, Gazi University, Institute of Science, 2018.