

TÜRK HAVA KURUMU ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Yapay Sinir Ağları ile Uçuşlardaki Gecikmelerin Öngörülmesi:

Esenboğa Havalimanında Bir Vaka Çalışması

YÜKSEK LİSANS TEZİ

Vahap Burhan DEMİR

Elektrik ve Bilgisayar Anabilim Dalı

Elektrik ve Bilgisayar Mühendisliği Programı

NİSAN 2016

TÜRK HAVA KURUMU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yapay Sinir Ağları ile Uçuşlardaki Gecikmelerin Öngörülmesi:
Esenboğa Havalimanında Bir Vaka Çalışması

YÜKSEK LİSANS TEZİ

Vahap Burhan DEMİR

1203617016

Elektrik ve Bilgisayar Anabilim Dalı
Elektrik ve Bilgisayar Mühendisliği Programı

Tez Danışmanı : Yrd. Doç. Dr. Engin Demir

Türk Hava Kurumu Üniversitesi Fen Bilimleri Enstitüsü'nün 1203617016 numaralı Yüksek Lisans öğrencisi, Vahap Burhan DEMİR ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “Yapay Sinir Ağları ile Uçuşlardaki Gecikmelerin Öngörülmesi: Esenboğa Havalimanında Bir Vaka Çalışması” başlıklı tezini, aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : Yrd. Doç. Dr. Engin DEMİR

Türk Hava Kurumu Üniversitesi



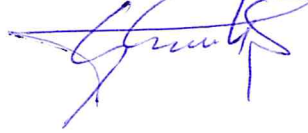
Jüri Üyeleri : Yrd. Doç. Dr. Tayfun KÜÇÜKYILMAZ

TED Üniversitesi



Yrd. Doç. Dr. Gülesin Sena DAŞ

Kırıkkale Üniversitesi



Tez Savunma Tarihi : 19.04.2016

TÜRK HAVA KURUMU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ'NE

Yüksek Lisans Tezi olarak sunduğum, Yapay Sinir Ağları ile Uçuşlardaki Gecikmelerin Öngörülmesi: Esenboğa Havalimanında Bir Vaka Çalışması adlı çalışmamın, tarafımdan akademik etik ve kurallara aykırı düşecek bir yardıma başvurmaksızın yazıldığını ve yararlandığım kaynakların kaynakçada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve bunu onurumla doğrularım.

19.04.2016

Vahap Burhan DEMİR



TEŞEKKÜRLER

Yüksek Lisans tez çalışma sürecinde beni yönlendiren, karşılaştığım zorlukları bilgi, tecrübesi, titiz ve detaylı çalışma mantığı ile aşmamda yardımcı olan desteğini ve yardımını hiçbir zaman esirgemeyen tez danışmanım değerli Yrd. Doç. Dr. Engin DEMİR'e teşekkürlerimi sunarım.

Çalışma boyunca bilgi ve deneyimleri ile yol gösteren Doç. Dr. Mehmet Emin TAĞLUK ve Yrd. Doç. Dr. Ömer Faruk ERTUĞRUL'a müteşekkirim.

Veri setini elde etmeme yardımcı olan Esenboğa Havalimanı Baş Müdür Yardımcısı Murat TUNA'ya, konu hakkındaki bilgi ile yardımlarını esirgemeyen Elektrik-Elektronik Mühendisi İlknur KABAKLI, Bilgisayar Mühendisi Ali GÜNEŞ ve Dr. Suat TORAMAN'a, engin Türkçe bilgisi ile tezin dilbilgisi yönünden desteğini sağlayan Coşkun MUTLU'ya teşekkür ederim.

Hayatım boyunca olduğu gibi tez çalışmalarım da her zaman yanımda olan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen, her konuda sabırla yardımcı olan sevgili eşim Yasemin DEMİR, oğullarım Melih Said DEMİR ve Ahmet Kağan DEMİR'e teşekkürlerimi, sevgi ve saygılarımı sunarım.

Nisan, 2016

Vahap Burhan DEMİR

İÇİNDEKİLER

TEŞEKKÜRLER	iv
İÇİNDEKİLER	v
TABLolar	vii
ŞEKİLLER	ix
KISALTMALAR	x
ÖZET	xi
ABSTRACT	xiii
BİRİNCİ BÖLÜM	1
İKİNCİ BÖLÜM	4
ÜÇÜNCÜ BÖLÜM	14
3.1 Veri Seti	14
3.1.1 Veri Setinin Özellikleri.....	14
3.1.2 Öznitelikler	17
3.2 Uygulanan Metodoloji	20
3.2.1 Özellik Seçimi	22
3.2.2 Yapay Sinir Ağları.....	24
3.2.2.1 Yapay Sinir Hücresinin Yapısı	25
3.2.2.2 Yapay Sinir Ağı'nın Yapısı	28
3.2.3 Doğrulama Yöntemi	30
3.2.3.1 Çapraz Doğrulama	30
3.2.3.2 Kayan Pencere Yöntemi	31
3.3 Çalışmada Kullanılan Araç, Gereç ve Ortam	31
DÖRDÜNCÜ BÖLÜM	32
4.1 Kullanılan Algoritma ve Yaklaşımlar.....	32
4.1.1 Özellik Seçimi	32
4.1.2 Uygun YSA Yapısının Belirlenmesi	33
4.1.3 YSA'nın Çalıştırılması	38

4.1.3.1 Kategorik Özniteliklerin Sahte Özniteliklere Dönüşülmesi İle YSA'nın Çalıştırılması.....	46
4.1.4 Zaman Boyutunda Uygulama ve İnceleme.....	48
4.1.5 Dakika Bazlı Uygulama ve İnceleme	52
4.1.6. Öznitelik Bazlı Uygulama ve İnceleme	54
BEŞİNCİ BÖLÜM.....	55
KAYNAKÇA.....	57
Ek A	61
DENKLEMLER	61
Ek B.....	62
TEST VERİLERİNE GÖRE BAŞARIM ORANLARI	62
Ek C	65
UÇUŞ AMAÇLARI	65
Ek D	68
MATLAB'TA ÇALIŞAN EĞİTİM FONKSİYONLARI	68
ÖZGEÇMİŞ	69

TABLÖLAR

TABLO 3.1: UÇUŞ BİLGİLERİ VERİ SETİ ÖRNEĞİ	14
TABLO 3.2: UÇUŞ AMACINA GÖRE ETİKETLERİN DAĞILIMI	15
TABLO 3.3: UÇUŞLARIN DAĞILIMLARI.....	16
TABLO 3.4: UÇUŞ GECİKME TAHMİNİ MODELLENE YSA'DA KULLANILAN AKTİVASYON FONKSİYONLARI.....	27
TABLO 4.1: ELDE EDİLEN ÖZELLİK SIRALARI	33
TABLO 4.2: TEK KATMANLI YSA'DA FARKLI PARAMETRELER İÇİN BAŞARIM ORANLARI.....	36
TABLO 4.3: ÖZELLİK SEÇİMİ İÇİN TAHMİNİ MAHALANOBİS MESAFELERİ TOPLAMI KULLANILDIĞINDA YSA'NIN BAŞARIM SONUÇLARI.....	41
TABLO 4.4: ÖZELLİK SEÇİMİ İÇİN ÖKLİD MESAFELERİNİN KARELERİNİN TOPLAMI KULLANILDIĞINDA YSA'NIN BAŞARIM SONUÇLARI.....	41
TABLO 4.5: : YSA'NIN ÖĞRENMESİ İÇİN KULLANILAN VERİ DAĞILIMLARI, MAHA-S KULLANILARAK SEÇİLEN ÖZELLİKLER VE BAŞARIM SONUÇLARI.....	44
TABLO 4.6: YSA'NIN ÖĞRENMESİ İÇİN KULLANILAN VERİ DAĞILIMLARI, EUCL-S KULLANILARAK SEÇİLEN ÖZELLİKLER VE BAŞARIM SONUÇLARI.....	45
TABLO 4.7: KATEGORİK ÖZNİTELİKLERİN SAHTE ÖZNİTELİKLERE DÖNÜŞÜLMESİ İLE ELDE EDİLEN ÖZELLİK SIRALARI.....	46
TABLO 4.8: KATEGORİK ÖZNİTELİKLERİN SAHTE ÖZNİTELİKLERE DÖNÜŞÜLMESİ İLE YSA'NIN ÇALIŞTIRILMASI SONUCUNDA SEÇİLEN ÖZELLİKLER VE BAŞARIM SONUÇLARI	47
TABLO 4.9: UÇUŞ GECİKME TAHMİNİ İÇİN TASARLANAN YSA'NIN ÖZELLİK SEÇİMİ KULLANILARAK ELDE EDİLEN SONBAHAR MEVSİMİ İÇİNDEKİ BAŞARIM ORANLARI.....	49

TABLO 4.10: UÇUŞ GECİKME TAHMİNİ İÇİN TASARLANAN YSA’NIN ÖZELLİK SEÇİMİ KULLANILARAK ELDE EDİLEN KIŞ MEVSİMİ İÇİNDEKİ BAŞARIM ORANLARI	50
TABLO 4.11: UÇUŞ GECİKME TAHMİNİ İÇİN TASARLANAN YSA’NIN ÖZELLİK SEÇİMİ KULLANILARAK ELDE EDİLEN İLKBAHAR MEVSİMİ İÇİNDEKİ BAŞARIM ORANLARI.....	50
TABLO 4.12: UÇUŞ GECİKME TAHMİNİ İÇİN TASARLANAN YSA’NIN ÖZELLİK SEÇİMİ KULLANILARAK ELDE EDİLEN YAZ AYI İÇİNDEKİ BAŞARIM ORANLARI	51
TABLO 4.13: YSA’NIN MEVSİMSSEL ZAMAN BOYUTUNDA PARAMETRE DEĞERLERİ	51
TABLO 4.14: ESENBOĞA HAVALİMANINDAN 2014 YILI İÇİN ALINAN UÇUŞ BİLGİLERİNİN DAKİKA BAZLI GECİKME DAĞILIMI.....	52
TABLO 4.15: ESENBOĞA HAVALİMANINDAN 2014 YILI İÇİN ALINAN UÇUŞ BİLGİLERİNİN DAKİKA ARALIK BAZLI GECİKME DAĞILIMI.	53
TABLO 4.16: BÖLÜM 4.1.3’TE ANLATILAN TABLO 4.5’TE DETAYLARI VERİLEN YSA’NIN SONUÇLARININ DAKİKA BAZLI DOĞRU SINIFLANDIRMA ORANLARI	53
TABLO 4.17: BÖLÜM 4.1.3’TE ANLATILAN TABLO 4.5’TE DETAYLARI VERİLEN YSA’NIN SONUÇLARININ DAKİKA ARALIK BAZLI DOĞRU SINIFLANDIRMA ORANLARI	54

ŞEKİLLER

ŞEKİL 3.1: GÜN İÇERİSİNDEKİ HER UÇUŞ SAATİ İÇİN YILLIK	
ORTALAMA GECİKME SÜRESİ.....	17
ŞEKİL 3.2: YSA İLE SINIFLANDIRMA AKIŞ DİYAGRAMI.....	21
ŞEKİL 3.3: YAPAY SİNİR HÜCRESİ MODELİ	26
ŞEKİL 3.4: YAPAY SİNİR AĞI YAPISI.....	28
ŞEKİL 3.5: İLERİ BESLEMELİ YSA MODELİ	29
ŞEKİL 3.6: GERİ BESLEMELİ YSA MODELİ	29
ŞEKİL 4.1: VERİ SETİNDEKİ DENGESİZ DAĞILIM PROBLEMİ İÇİN	
GELİŞTİRİLEN KAYAN PENCERE YÖNTEMİ	39
ŞEKİL 4.2: UÇUŞ GECİKMELERİ İÇİN TASARLANAN YSA'NIN	
MATLAB'TA ÇALIŞTIRILMASI	43

KISALTMALAR

YSA : Yapay Sinir Ağları

UHK : Uluslararası Havalimanları Konseyi (ACI)

QNH : Ortalama Deniz Seviyesindeki Atmosfer Basıncı Deęeri

İHA : İnsansız Hava Aracı

HTKS : Hava Trafik Kontrol Sistemi (ATC)

UHTB : Uluslararası Hava Taşımacılığı Birliği (IATA)

WITI : Hava durumu Etkisi Trafik İndeksi (Weather Impacted Traffic Index)

ÖZET

Yapay Sinir Ağları ile Uçuşlardaki Gecikmelerin Öngörülmesi: Esenboğa Havalimanında Bir Vaka Çalışması

DEMİR, Vahap Burhan

Yüksek Lisans, Elektrik ve Bilgisayar Anabilim Dalı

Tez Danışmanı: Yrd. Doç. Dr. Engin DEMİR

Nisan–2016, 84 sayfa

Hava taşımacılığı, ulaşım sistemleri içerisinde önemli bir yere sahip olup uçuşların planlanan zamanlarda seferlerini gerçekleştirmesi, yolcuların konforu ve işletme maliyetlerin kontrol edilebilirliğini sağlamak için gereklidir. Amerika Birleşik Devletleri Ulaştırma Bürosu tarafından yayınlanan bilgiye göre 2015 yılındaki uçuşların %19.63'ü gecikme ya da iptallerden dolayı zamanında gerçekleşmemiştir. Uçuş gecikmelerinin hava durumu, hava trafiğinde yaşanan yoğunluk, kaza veya kapanan uçuş pistleri, uçaklar arasındaki mesafenin arttırılmasına sebep olabilecek koşullar ve yer hizmetlerinde yaşanabilecek işletmeden kaynaklı gecikmeler gibi çok çeşitli nedenleri bulunmaktadır. Bu çalışmada havalimanında bulunan çeşitli algılayıcılardan toparlanan veriler ve uçuşla ilgili bilgiler kullanılarak yapay sinir ağları ile uçuşlardaki kalkış gecikmelerini tahmin eden bir yapay sinir ağı modeli geliştirilmesi hedeflenmiştir.

Gerek akademik çalışmalarda gerekse endüstriyel ürünlerde uçuş kontrol sistemleri içerisinde uçuş gecikmelerini tahmin edebilen modeller önerilmiştir. Literatürde hava koşulları ve uçuş bilgileri kullanılarak uçuş gecikmelerinin tahmini için Bayes ağları, karar ağaçları, istatistiki yoğunluk tahminleri kullanılan en popüler yöntemlerdir. Bu çalışmada doğrusal olmayan sistemleri modelleyebilmesi ve hızlı

çalışması nedeniyle çok katmanlı, geri beslemeli yapay sinir ağıları kullanılmıştır. Deneysel çalışmalarda kullanılan veri seti 2014 yılı içerisinde Ankara Esenboğa Havalimanında toparlanmıştır. Veri seti 39.892 uçuş için planlanan kalkış zamanındaki 9 çeşit hava ölçüm değeri ve 3 adet uçak/uçuş ile ilgili bilgiden oluşan öznitelik kümesini içermektedir. Yapay Sinir Ağı modeli ile uçuşlardaki kalkış gecikmeleri ortalama bütün veri kullanıldığında genel ortalama % 93, zamanında ve gecikmeli uçuşlar dengeli bir şekilde zaman pencerelerine parçalanarak kullanıldığında genel ortalama % 96'ya kadar ulaşan bir başarımla elde edilmiştir. Ön işlemede kullanılan öznitelik seçme yöntemleri başarımlarını artırmıştır.

Anahtar Kelimeler: Uçuş gecikme tahmini, sınıflandırma, yapay sinir ağıları, öznitelik sıralama.

ABSTRACT

Predicting Flight Delays with Artificial Neural Networks :

A Case Study in Esenboğa Airport

DEMİR, Vahap Burhan

Masters in Electrical and Computer Engineering Department

Supervisor: Assistant Professor Dr. Engin DEMİR

April–2016, 84 pages

Air transportation has an important place among transportation systems and it is indispensable for the flights to perform their voyages in scheduled time in order to ensure the comfort of passengers and controllability of operational costs. According to the report published by United States Bureau of Transportation 19.63% of flights in 2015 didn't take place on time because of delays and cancellations. There are several reasons for flight delays like weather conditions, excessive intensity in air traffic, accidents or closed airfields, conditions that will lead to an increase in distances between planes and operational delays in ground services. In this study, using the data collected from the sensors located in the airport and the information about the flight, the goal is develop a machine learning model to estimate departure delays of flights using artificial neural networks.

In both academic studies and industrial products, models that can estimate flight delays are proposed. In the literature, Bayes networks, decision trees, and statistical density estimates are the popular methods to estimate flight delays using weather conditions and flight information. In this study multilayer, feedback artificial neural networks are used due to its ability to model nonlinear systems and fast execution times. The data set used in the experimental study is gathered from Ankara Esenboğa

Airport in year 2014. For each of the 39.892 flights in data set, it contains a set of attributes consisting of 9 different weather measurements in scheduled departure time and 3 attributes related to the plane/flight. Using the proposed artificial neural network model if the all data is used in learning on the overall 93% accuracy and if data is observed by time window frames including equal number of on-time and delayed flights on the overall up to 96% accuracy is attained. The feature selection algorithms utilized in the preprocessing was shown to increase accuracy.

Key words: Flight delay estimation, classification, artificial neural networks, feature ranking.



BİRİNCİ BÖLÜM

GİRİŞ

Uçuş gecikmeleri havacılık sektöründe yaygın bir durumdur. 2012 yılının ilk iki ayında Amerika Birleşik Devletleri'nde rapor edilen uçuş gecikmelerinin oranı yaklaşık % 25 olmuştur (Ferrer, Oliveira, & Parasuraman, 2012). Uluslararası Sivil Havacılık Organizasyonu'nun yayınladığı bilgilere göre 2014 yılında Dünya üzerindeki tüm kalkışların % 35'i gecikmeli gerçekleşmiştir. (İngiltere Sivil Havacılık Sitesi, 2016)'nin vermiş olduğu bilgilere göre de İngiltere'de 2015 yılında uçuşların % 23'ü gecikmeli gerçekleşmiş ve ortalama gecikme süresi 13 dakika olarak bildirilmiştir. Amerika Birleşik Devletleri Ulaştırma Bürosu tarafından yayınlanan bilgiye göre 2015 yılındaki uçuşların % 19.63'ü (1.048.488 adet) gecikme ya da iptallerden dolayı zamanında gerçekleşmemiştir. (Bir Bakışta Uçuş Gecikmeleri : ABD Ulaştırma Bürosu, 2016)

Dünya üzerinde yaşanan tüm uçuş gecikme ve iptallerin toplam maliyeti 1991 yılında yaklaşık 2 milyar dolar olmuştur (Vranas, Bertsimas, & Odoni, 1994). (Robinson, 1989) Atlanta'da ki her bir havayolu için yıllık 6 milyon Amerika Doları olarak bildirilen gecikme sonucundaki maliyetlerin azaltılması için daha doğru tahmin yapılması gerektiğini bildirmiştir. Çeşitli nedenlerle meydana gelen gecikme ve iptallerin toplam maliyetlerinin sadece Ocak 2014'ün sonundaki Amerika'ya maliyetinin toplam 2,5 milyar dolar olduğu bildirilmiştir (CNN, 2014). Planlanmış uçuşlarda yaşanan gecikmeler havayolu firmalarına ciddi maliyetler yaratmakta, yolcuların memnuniyetlerini azalttığından havayolu firmasının marka değerini olumsuz yönde etkilemektedir. Bu sebeple birçok ülke, vatandaşlarının yaşanması muhtemel bu gecikmelerden doğan zararlarını karşılamak için caydırıcı yasalar çıkarmışlardır. Örneğin Amerika Birleşik Devletleri'nde, Ulaştırma Bakanlığı dört

saatten fazla gecikme yaşayarak, havalanmadan pistte kalan uçaklar için yolcu başına 27.500 \$ para cezası uygulamaktadır. Avrupa yasaları ise üç saatten fazla uçuş gecikmeleri, iptaller ve mahrumiyetler için havayolunun yolcu başına 600 € 'ya kadar tazminat ödemesinin yolcu hakkı olduğunu belirtmektedir (EUR-Lex, 2015). Ancak bu caydırıcı yaptırımların varlığı uçuşlardaki gecikmelerin sıklıkla yaşanmasına engel olamamaktadır.

Önceki çalışmalarda uçuş gecikmelerinin başlıca nedenleri:

- Uygunsuz hava koşulları
- Hava trafiği yoğunluğu
- Havalimanı kapasitesi (yolcu, pist ve köprü sayısı gibi.)
- Teknik ve mekanik sorunlar
- Ulusal Havacılık Sistemleri
- Güvenlik

olarak sıralanmıştır.

(A. ZeinEldin, 2014)'e göre, United Airlines'in 2004 yılının ilk çeyreğinde kullanmış olduğu uçuş gecikme planlaması ile 1.6 milyar \$ tasarruf ettiği tahmin edilmektedir. Bu noktadan hareketle uçuşlar için geliştirilecek gecikme tahmin sistemlerinin gecikmeden kaynaklı maliyetlerin azaltılmasında ne kadar önemli olduğu ortaya çıkmaktadır. 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. Örneğin Zonglei ve arkadaşlarının (2008) yapmış oldukları bir çalışmaya göre, denetimli öğrenme algoritmaları kullanılarak büyük ölçekli uçuş gecikmelerinde bir alarm sistemi tasarlanmış ve aciliyet durumuna göre farklı renklerde alarmlar üretilmiştir.

Bu tez çalışmasında hava taşımacılığı sektöründe önemli bir sorun olan uçuş gecikmelerinin tahmin edilmesi üzerine bir çalışma yapılmış olup, literatürdeki benzer çalışmaların çoğundan farklı olarak tahmin sistemi için sadece hava koşulları değil aynı zamanda çeşitli uçuş ve uçak bilgileri de kullanılmıştır.

Tezin geri kalanı şu şekilde düzenlenmiştir: Bölüm 2'de literatür özeti verilmiş, Bölüm 3'te çalışmada kullanılan yöntemler ve veri setinin özellikleri sunulmuş, Bölüm

4'te deneysel alıřmalar zetlenmiřtir. Blm 5'te ise bu alıřmanın sonuları vurgulanmıř ve ileriki alıřmalarla ilgili neriler sunulmuřtur.



İKİNCİ BÖLÜM

LİTERATÜR ÖZETİ

Literatür incelendiğinde değişik veri setlerinde, çeşitli öznitelikler ile farklı yöntemler uygulanarak geliştirilen uçuş gecikme tahmini için çalışmalar bulunmaktadır. Çalışmalarda veri seti olarak tek havalimanı kullanıldığı gibi birden çok havalimanı verisi de kullanılmıştır. Aylık, yıllık ve 10 yılı bulan farklı tarih aralığındaki veriler kullanılmıştır. Çalışmalarda uçuş gecikme tahmini için genellikle karar ağaçları, bayes ağlar, regresyon ve olasılık tahminlerinin yanı sıra yapay sinir ağları da en çok kullanılan yöntemlerdir. Ekonomik kazanç ve insan konforu göz önünde bulundurularak, gecikme sürelerini tahmin etmek için literatürde bazı yaklaşımlar sunulmuştur. Bu yaklaşımlar genellikle hava koşulları üzerine inşa edilmiştir (Klein, Craun, & Lee, 2010).

(Valdez, 2000) hava koşullarının doğru bir şekilde tahmin edilmesinin, hava koşullarından kaynaklanan uçuş gecikmeleri açısından % 20 ile % 35 arasında bir azalma sağlayacağını bildirmiştir. İlk yıllarda hava koşullarından kaynaklanan gecikmeler tahmin, standart sapma, maksimum ve minimum değerler gibi temel istatistiksel değişkenlere dayanmaktadır (Robinson, 1989). Hava durumu bazlı tahmin tekniklerinin doğruluğunu artırmak ve havalimanlarındaki hava koşulları tahmini için regresyon, bayes ağlar gibi farklı çalışmalar da yapılmıştır (Hansen & Riordan, 2000).

(Zonglei, Jiandong, & Guansheng, 2008)'e göre, uçuş gecikmelerinin birçok nedeni vardır. Uçuş gecikmelerinin temel sebebi, hava sahasının ve havalimanlarının kapasitelerinin artan hava trafiği ihtiyacını karşılayamamasından kaynaklanmaktadır. Kötü hava koşulları, uçağın mekanik problemleri, yolcuların neden olduğu ve havayolu firmasının operasyonel sorunları da gecikmelere neden olan faktörler arasında sayılabilir. Amerikan Havayolları uçuşları için 2008 Eylül'ünde uçuşların % 33,1'i, Haziran ayında ise % 41,2'si gecikmeli varmıştır. (Brett, 2008).

Yapılan çalışmalar incelendiğinde birçok faktörün uçuş iniş ve kalkış zamanlamalarını etkilediği görülmektedir. (Bandyopadhyay & Guerrero, 2012)' ye göre uçuş kalkış saatleri ile kötü hava durumları arasında pozitif bir korelasyon olduğu gözlemlenmektedir. Özellikle akşam 8 saatleri daha fazla gecikme olma eğilimindedir. Ayrıca, kar, gök gürültülü yağmur, yağmur, karla karışık yağmur ve sis gibi olumsuz hava koşulları gecikmeler ile yüksek korelasyon göstermektedir.

Zonglei ve arkadaşlarının (2008) yapmış oldukları çalışmada güvenlik öne sürülerek ismini vermedikleri Çin'de ki bir havalimanında, denetimli öğrenme algoritmalarını kullanarak büyük ölçekli uçuş gecikmelerinde bir alarm sistemi tasarlamışlardır. Bayes ağları ve karar ağaçları kullanılarak uçuş gecikme seviyesine göre farklı renklerde alarmlar üretmişlerdir. Eğer kalkışların % 40'tan fazlası kötü hava koşulları veya rota kontrolü için gecikecek olursa mavi renkte, 4 saatten fazla gecikmeli 10'dan fazla uçuş veya kötü hava durumlarından kaynaklanan 2 saat içerisinde geciken uçuş sayısı % 60'tan daha fazla olursa sarı renkte, kötü hava durumlarından kaynaklanan 2 saat içerisinde geciken uçuş sayısı % 80'den daha fazla olursa turuncu renkte, önümüzdeki 2 saat içerisinde kötü hava durumu sebebiyle uçuşların tümü iptal edilirse kırmızı renkte alarmlar üretilmektedir. Başarı oranlarının % 80'den az olmadığını iddia etseler de öznitelik olarak sadece hava durumu parametrelerini kullanmışlardır. Çalışma sonucunda uçuş gecikmelerinin ana faktörünün hava durumu olmadığını ve kötü hava koşulları nedeniyle gecikmeli uçuş oranının tüm gecikmeli uçuş oranına göre sadece % 4,63'üne tekabül ettiğini belirtmişlerdir.

(Martinez, 2012) ise yaptığı yüksek lisans tez çalışmasında diğer birçok çalışmanın aksine belli bir dakikanın üzerinde olan uçuş varış gecikmelerini tahmin etmeye çalışmıştır. Çalışmada veri kümesi olarak Amerika Birleşik Devletleri Ulaştırma İstatistikleri Bürosu tarafından sağlanan ve sadece tüm önemli havayolu şirketlerinin 1995 ve 2010 tarihleri arasında büyük havalimanlarındaki iç hat uçuşları ele alınmış ve veri boyutunun yaklaşık 14 milyon kayıt olduğu belirtilmiştir. Tasarlanan model birkaç ay gibi uzun vadeli tahminler için çalışmakta kısa vadeli tahminlerde ise başarılı olamamaktadır. Çalışılan veri seti aşağıdaki gibi açıklanmıştır:

- **Kimlik bilgileri:** Uçuş numarası, tarih ve kuyruk numarası.

- **Uçuş bilgisi:** (American Airlines için AA gibi) taşıyıcı kodu, kökeni ve hedef havalimanları kodları.
- **Zaman bilgisi:** Zamanlanan ve gerçek kalkış (veya varış) saati ve kalkış veya varış gecikmesi arasındaki fark (1 dakikalık hassasiyet ile).
- **Uçuş süresi bilgileri:** Planlanan ve gerçek zaman.
- **Zemin bilgileri:** Yere yakın uçuş süresi ve havalanma veya iniş saati.
- **Gecikme nedeni (varsa):** Hava trafik kontrolü, güvenlik veya önceki uçuştan dolayı uçağın varışının gecikmesi, havayolu firması ve hava durumları ile ilişkilendirilebilir gecikme parçası.

Ampirik birikimli dağılım fonksiyonu, kernel yoğunluk tahmini ve koşullu tahmin modelleri kullanılmıştır. Sonuç olarak en iyi gecikme tahmin metodunun tüm kategorik parametrelerin kombinasyonunu ve varış saatindeki durumu dikkate alan koşullar olarak belirlenmiştir. Elde edilen tahmin sonuçlarının literatürde kullanılan FlightCaster metodundan daha iyi sonuçlar verdiği belirtilmiştir. Çekirdek yoğunluklu tahmin sistemlerinin de çok başarılı sonuçlar verdiği belirtilmiş ancak ne oranda tahmin başarıları sağladıkları konusunda açıklayıcı bilgi verilmemiştir.

(A. ZeinEldin, 2014) “Uçuş gecikmeleri için yapay sinir ağı modelleme: sınıflandırma ve tahmin” adlı çalışmada, büyük maliyet ve zaman kaybına neden olan uçuş gecikmelerini tahmin etmeye çalışmıştır. Bu çalışmada amaçlanan uçuşun ne kadar gecikeceğini ve bunun diğer uçuşlar açısından etkisinin ne olacağını ve tüm gecikme faktörlerinden en çok hangisinin gecikmeye neden olacağını tahmin edilmesi amaçlanmaktadır. Model için veri seti olarak 2012 yılının tüm gecikmeli uçuşları ele alınmış ancak sadece Ocak, Haziran ve Kasım ayları hesaplamalarda kullanılmak üzere seçilmiştir. Fakat verilerin nereden alındığı belirtilmemiştir. Çalışmada yaklaşık 60 gecikme nedeni tespit edilmiş ve her bir nedene bir kod verilerek gruplandırılmıştır. Uçuş gecikme tahmini için ileri beslemeli, iki gizli katmanlı, hiperbolik tanjant aktivasyon fonksiyonlu, karelerin toplamı hata fonksiyonu kullanan YSA kullanılmış ve alınan veri setinin % 70’i öğrenme % 30’u da test verisi olarak ayrılmıştır. Alınan gecikmeli veri seti sayısı 3 ay için 10.123 olup, bunun 7.095’i öğrenme 3.025’i test verisi olarak ayrılmıştır. Çalışmada amaçlanan geciken uçuşların nedenini belirlenen 60 faktör arasında çoktan aza sıralamaktır. Başarım olarak ortalama % 78.86’lık bir başarı oranı yakalanmıştır. Sonuç olarak uçuş numarasının gecikme üzerinde % 26, kalkış havalimanının % 24, gecikme sayısının % 17 ve uçak

tipinin % 10 olarak tespit edilmiştir. İnsan faktörlü gecikme nedenlerinden uçak tipi, kalkış havalimanı, uçuş numarası, gecikme nedeni ve gecikmelerin sayısı uçuş gecikmelerinin en önemli nedenleri olarak tespit edilmiştir.

(B. Laskey, Xu, & Chen, 2012) yapmış oldukları çalışmada bayes ağları kullanarak farklı bileşenlerin uçuş gecikmesine olan etkilerini incelemişlerdir. Çalışmada kullanılan veriler Amerika Birleşik Devletleri Havacılık Sistemi Performans Metrikleri (ASPM) ve Ulusal Konvektif Hava Algılama (NCWD) veri tabanlarından alınmıştır. Veri seti olarak iki yönlü olarak Chicago O'Hare Uluslararası Havalimanı (ORD) ile Hartsfield-Jackson Atlanta Uluslararası Havalimanı (ATL) arasındaki 2004 yılı Haziran-Kasım ayındaki toplam 26.372 adet uçuş verisi kullanılmıştır. Haziran ayından 22 Eylül'e kadar olan veri eğitim verisi olarak kalan son bir haftalık veri ise test verisi olarak kullanılmıştır. Bunun için şu adımlar izlenmiştir.

Çalışmada çeşitli gecikme parametreleri kullanılmıştır. Bunlar uçağın uçuşa teknik olarak hazırlanması, yakıt alması, taşıyacağı kargoların yüklenmesi, kapıya geçiş yapması, pistte bekleme süresi (Motorun çalıştırılması, önceki uçuş sebebi ile pistin hazırlanmasının beklenmesi), havada geçen süre, iniş için sıra beklenmesi ve uçağın inmesi, uçağın kuyruk numarası ve uçak bilgileridir.

- Eğitim verileri üzerinde çapraz doğrulama yapılarak en önemli faktörler çıkarılarak ele alınmıştır,
- Bayes ağları üzerinde gecikme fazlarını gösterir düğümler yaratılmıştır,
- 1. aşamada seçilen bayes ağlar tarafından verilen düğümler ana düğümler olarak belirlenmiştir,
- Verilen düğümler için tahminler hazırlanmış ve burada 15 dakikalık gecikmeli tahminler yapılabilmektedir,
- Bayes ağlardan gelen düğümlerin güncellenmesi için eğitim verileri için Dirichlet-multinomial öğrenme metodu kullanılmıştır,
- Model örnek veriler üzerinde test edilmiştir.

Sonuçlar 0-15, 30-75 ve 105-120 ve 120 dakikadan fazla olmak üzere farklı kategorilerde ve geri dönüş fazı, taksi çıkış fazı ve hava fazı olarak 3 fazda değerlendirilmiştir.

Geri dönüş fazı açısından eğer uçuşlar zamanında havalanırsa, ancak 1 saatten fazla geri dönüş gecikmesi olursa normal hava koşullarında (İyi hava görüşü herhangi bir negatif etkili hava koşulu yok) % 93 olan zamanında olan uçuş oranı, 1 saat olan geri dönüş gecikmesine bağlı olarak % 81 zamanında olan uçuşa düşmüştür. Anormal hava koşullarında ise bu oran % 34 oranına gerilemiştir.

Taksi çıkış fazı açısından, uçuşların % 7'sinin gecikme sebebi olarak bu faz tespit edilmiştir. Burada kastedilen uçağa yolcu ve yüklerin yüklenmesi, mekanik arızalar ve bilinmeyen nedenlere bağlı gecikmelerdir.

Hava fazı açısından ORD ve ATL havalimanları arasının 89 dakika sürdüğü tespit edilmiştir. Hava fazında hava koşullarına bağlı 15 dakikanın üzerinde gecikmeler % 47 olarak hesaplanmıştır.

Alınan sonuçlarda bu uygulama hava durumunun yanında diğer durumların iki havalimanı incelenerek ne kadar gecikme üzerinde etkisi olduğu çıkarılmıştır. Sonuçlar bayes ağların ne kadar etkin kullanımı olduğunu çıkarması açısından iyidir. ORD'de ki gecikmeler genellikle kapılardan gecikmeli çıkışlara bağlı olurken ATL'de (Hedef havalimanı) hava durumu etkileri daha fazla gözlemlenmiştir. Model yaz ayları için çalıştırıldığından kış mevsimi için farklı sonuçların çıkacağı bildirilmiştir.

(Fleurquin, Ramasco, & M. Eguiluz, 2013) ise “Şiddetli meteorolojik koşullar altında sistematik gecikme tahmini için veri-tabanlı modelleme” adlı çalışmalarında, uçuş gecikmelerinin çok fazla para kaybına neden olması ve bunun yanı sıra küresel ısınmanın en önemli faktörlerinden biri olan CO_2 salınımını da arttırması nedeniyle veri tabanı sistemleriyle uçuş gecikmelerinin nedenlerinin ve gecikme sürelerinin dağılımının çıkarılması için çalışmışlardır. Sistemin çalıştırılması için tüm ABD çapında bir çalışma yapılmış, bunun için gün olarak en çok gecikmelerin yaşandığı 27 Ekim 2010 tarihi seçilmiştir. Meteorolojik verilere göre o gün Elddis kasırgasının ABD'yi vuracağı tahmin edilmektedir.

Bu çalışma için 3 tane veri kaynağı ele alınmıştır. Bunlar gecikme verisi, saat dilimi dönüşümü ve havalimanı bağlantısı verileridir. Gecikme verileri Amerika

Birleşik Devletleri Ulaştırma İstatistikleri Bürosu'ndan alınmıştır. 305 ticari havalimanındaki 18 havayolunun toplamda 6.450.129 adet verisi alınmıştır. ABD'de 2010 yılında 8.687.800 adet uçuş gerçekleşmiş ve bunlardan % 74'ü veri tabanına aktarılabilmektedir. Hedeflenen modeli yapmak için elde edilen uçuş bilgileri arasında, uçak ve havayolu kimlik kodu (Sırasıyla kuyruk numarası ve havayolu id), uçuş tarihi, gerçek ve zamanlanmış kalkış ve varış zamanları, kalkış ve hedef havalimanları ve uçuşun iptal ya da yönlendirilip yönlendirilmediği bilgileri bulunmaktadır. Saat dönüşümü ise farklı saat dilimlerindeki verilerin birbirine dönüştürülmesini içermektedir. Havalimanı verileri ise uçakların yolcu ve personel kaynaklı gecikmelerini belirlemektedir. Çalışmanın amacı havalimanından havalimanına olan gecikmelerin matematiksel olarak modellenmesidir. Bu bağlamda havalimanından havalimanına gecikmeler formülize edilmiş ve seçilen gün için hesaplamalar yapılmıştır. Data-driven modeling üzerine kurulu bir model geliştirilmiştir. Bu çalışmada her bir havalimanı için kontrol edilebilen havalimanı servis kapasitesini ifade eden β parametresi belirlenmiş ve bu parametre kullanılarak her bir havalimanındaki veriler ile matematiksel formüller çıkarılmıştır. Havalimanı koşullarına bağlı belirlenen bu parametre ile gecikmelerin tahmin edilebileceği sistem geliştirilmiştir.

Bu sistem günlük gecikmeleri ve havalimanı ağını içermektedir. Çalışmanın sonucunda numerik bir başarımlı verisi verilmemiştir. Giriş verileri ile iptal edilen uçuşları da giriş verisi olarak düşünüldüğünde sonuçlarla tahmin verileri arasında yakın sonuçlar elde edildiği bildirilmiştir. Ancak bu çalışmada ele alınan giriş verilerine daha sonra iptal edilen uçuşlar eklenmiş ve bahsedilen kasırganın Amerika'nın doğu kısmını vurduğu belirtilmiş ve New York, Atlanta ve Georgia eyaleti gibi tamamen büyük şehirlerde uçuşlar iptal edilmiş dolayısıyla ülke çapında model çıkarması amaçlanırken ülkenin birçok büyük ve önemli havalimanı ihmal edilmiştir.

(Xu, Sherry, & Laskey, 2008)'nin yapmış olduğu "ABD havalimanlarında çok faktörlü gecikme tahmini" adlı başka bir çalışmada ABD'deki 34 havalimanınının 2005 yılı yaz ayındaki (Haziran-Temmuz-Ağustos) 3 aylık veri ile her birinde 15 dakikalık havalimanı gecikmeleri tahmini için çok faktörlü modelleri açıklamaya çalışılmıştır. Veri setinde Hava Durumu Etkisi Trafik İndeksi (WITI) tarafından sağlanan bulut yüksekliği, sıcaklık, rüzgâr, görüş mesafesi gibi çeşitli hava durumu bilgileri,

zamanlanmış, kalkışlarda havalimanının kapasitesi ve operasyon taleplerinin oranı, havalimanı kapasitesi aşıldığında uçuş hacmini azaltmak adına kalkışlar için verilen holding time, planlanmış geri dönüş süresi, havayolu firmasından kaynaklanan uçak temizliği, bagaj, engelli yolcular, yakıt bekleme gibi nedenler, resch numerik parametresi ile tutulan uçak değişikliği olup olmadığı, planlanan kalkış saati bilgileri bulunmaktadır. Modeller Multi-Adaptive Regression Splines (MARS) ve Piece-Wise Doğrusal Regresyon kullanılarak 34 havalimanının her biri için elde edilen verilerle geliştirilmiştir. Burada “Generated” ve “Absorbed” adında iki tür gecikme tanımlanmıştır. Generated gecikme zaman çizelgesine göre geri kalınan zamanı ifade ederken, absorbed ise buna göre erken hazırlanmayı ifade etmektedir. Yani absorbed eksi bir gecikmedir. Bunun yanı sıra uçuş süresince olan gecikme ise “airborne” gecikme diye ifade edilir. Böylece toplam gecikme “generated + airborne – absorbed” şeklinde ifade edilir. Burada teknik olarak MARS regresyon gecikmeleri öğrenir ve buna göre tahminlerde bulunur. MARS model gecikmelerinin farklı nedenlerini toplar ve artı ve eksi gecikmeleri hesaplar ve toplam gecikmeyi çıkarır. Generated gecikme modelleri için ortalama Dönüştürülmüş Mutlak Tahmin Hatası (MTAPE) 5.3 dakikadır. Havalimanları arasında bu oran 9.2 ile 3.4 dakika arasında değişmektedir. Absorbed gecikme modelleri için ise 2.2 dakikadır. 34 havalimanı arasındaki aralık ise 1.9 ile 2.7 dakika arasında değişmektedir.

(Sridhar, Wang, Klein, & Jehlen, 2009) “ABD’de ulusal, bölgesel ve havalimanı bazında uçuş gecikme ve iptallerini modelleme adlı çalışmalarında” hava koşullarına bağlı uçuş gecikmelerini ulusal bölgesel ve havalimanı bazında açıklamaya çalışmışlardır. Tasarlanan modeller beklenen hava durumu tarafından etkilenen uçakların sayısına dayalı gecikme tahmin yapmaya çalışmaktadır. Verilen bir zamandaki hava durumuna bağlı olarak etkilenen uçak sayısını veren Hava durumu Etkisi Trafik İndeksi (WITI) kullanılmıştır. Bu çalışmada Federal Havacılık İdaresi (FAA) tarafından sağlanan operasyonel OPSNET ve ASPM veri tabanı kullanılmıştır. OPSNET 1990’dan beri ASPM ise 2000’den beri veri toplamaktadırlar. OPSNET 15 dakika üzeri gecikmeleri bir gün boyunca tüm uçakların yaşadığı gecikmelerin toplamı olarak tutmaktadır. ASPM ise dünya çapında havayolu firmaları için rezervasyon bazlı gecikmeleri tutan en iyi veri tabanı olarak bilinir. Veri setindeki özellikler: çeşitli kategorilerde gecikme süreleri, havayolundan kaynaklanan gecikmeler, hava durumu bilgileri ve pist bilgileridir.

Bu çalışmada tahmin modelleri için gerileme yöntemleri ve YSA kullanılmıştır. Çalışmada çeşitli YSA modelleri ile geleneksel lineer regresyon modellerinin performansı karşılaştırılmıştır. Sonuçlar 2005-2008 dönemindeki trafik, hava durumu ve gecikme verilerine dayanmaktadır. Regresyon yöntemi ve diğer veri madenciliği teknikleri veriyi modellemek için kullanılmıştır. İleri beslemeli YSA kullanılmış ancak diğer parametreleri hakkında bir bilgi verilmemiştir. Çalışmanın sonucunda doğrusal regresyon yöntemleri ile ortalama % 75, YSA ile % 80 oranında uçuş gecikme tahmininde bulunulmuştur. Gecikmelerin en önemli nedeni hava koşulları olarak tespit edilmiş, farklı mevsimlerde farklı tekniklerin tahminde kullanılmasının daha uygun olacağı sonucu çıkarılmıştır. Ayrıca YSA'nın tahmin için çok daha fazla veri seti üzerinde çalıştırılabileceğinden daha çok uçuşun olabileceği zamanlarda etkili sonuçlar elde edilebileceği bunun yanı sıra regresyon yöntemlerinin diğer zamanlarda da kullanılabileceği sonucuna varılmıştır. Son olarak bu modelde kullanılan veri tabanının sonuçlara bir etkisi olmadığı bilgisi verilmiştir.

(Dey, Phillips, & Steele, 2009) yapmış oldukları çalışmada Monte Carlo algoritması ve network optimizasyon tekniği kullanılarak uçuş gecikmelerini en kısa yollar algoritmasının bir alt çözümü olarak rota üzerinde gecikmeyi minimize edecek bir çalışma yapılmıştır. Veri seti olarak Amerika Birleşik Devletleri Ulaştırma İstatistikleri Bürosu'ndan 1987'den 2008'e kadar olan tüm iç hat Amerika uçuşları alınmıştır. Bu veri seti 120 milyondan fazla kayıt ve 12 GB'dan fazla boyuta sahiptir. Bu sebeple veri seti sadece American Airlines (AA), Continental Airlines (CO), Delta Airlines (DL), Southwest Airlines (WN), American Eagle Airlines (MQ), United Airlines (UA) ve SkyWest Airlines (SW) havayollarını ve 1987, 1992, 1997 ve 2002 yıllarını kapsayacak şekilde küçültülmüştür. Analiz verisi olarak bu veriler kullanılmıştır. Simülasyon verisi olarak ise aynı havayollarının 2005'den 2008'e kadar olan uçuşları ele alınmıştır. Veri setindeki özellikler şunlardır: Yıl, ay, gün, her uçuş için kalkış ve varış saati, havayolu, taksi giriş ve çıkışı, kalkış ve varış havalimanları bilgileridir. Çoklu doğrusal regresyon modeli verinin karakteristiğinden dolayı tercih edilmiştir. Kullanılan veri seti %70 oranında istenilen özelliklere göre sadeleştirilmiştir. Cascade-Ensemble örnekleme metodu örnekleme için seçilmiştir. Elde edilen veriler için yapılan formülizasyon Java, Python ve C'de yazılan programlarla gerçekleştirilmiştir. Sonuç olarak % 11'lik bir hata oranı gecikme

tahmini yapılabildiği belirtilmiştir. Ancak geliştirilen model en iyi iki ayaklı uçuşlarda başarı sağlarken 3 ayaklı uçuşlarda hata oranının arttığı belirtilmiştir.

(Cheng, 2014) “Büyük gerçek zamanlı veri kullanarak risk yönetimi” adlı 2014 tarihli master tezinde, uçuş için hava durumu, havalimanı gibi temel faktörlerin uçuş gecikmelerine etkisinin hesaplanmasını amaçladığı bir tahmin modeli üzerinde çalışmıştır. Veri olarak Amerika Birleşik Devletleri Ulaştırma İstatistikleri Bürosu’ndan alınan San Francisco Uluslararası Havalimanı ve Denver Uluslararası Havalimanı verileri kullanılmıştır. Burada AirTran Airways (FL), Alaska Airlines (AS), American Airlines (AA), American Eagle (MQ), Delta Air Lines (DL), ExpressJet Airlines (EV), Frontier Airlines (F9), Hawaiian Airlines (HA), JetBlue Airways (B6), SkyWest Airlines (OO), Southwest Airlines (WN), United Airlines (UA), US Airways (US), Virgin America (VX) havayollarına ilişkin Haziran 2003 verileri alınmıştır. Hava durumu olarak normal hava koşulları ve olağanüstü hava koşulları ele alınmıştır. Hava durumu parametreleri olarak rüzgâr, sis, gökyüzü açıklık durumu, bulut kalınlığı, kum fırtınası ve yağış parametreleri gibi parametreler kullanılmıştır. Hava durumu analizi içinse çoklu doğrusal regresyon kullanılmıştır. Böylece dakika bazında hava durumunun matematiksel analizi çıkarılmıştır. Veri seti olarak 30.000'in üzerinde kayıt üzerinde çalışılmıştır. Bu çalışmanın sonunda uçuş gecikmelerine hava durumu ve tatil etkisi ortaya çıkmıştır. Tatil etkisinin neredeyse hava durumu ile aynı etkiyi yarattığı gözlemlendiğinden havalimanında artan taleplerin gecikmelere etkisi açısından önemli bir parametre olduğu ortaya çıkarılmıştır. Bu sebeple bu iki verinin kullanılmasıyla yapılan tahminler % 80'den fazla başarı sağlayabilmiştir. Ayrıca modellemeler için bayes ağlar kullanılmıştır. Bunun için öncelikle veriler bir veri tabanına aktarılmış ve veriler % 90 oranında düzleştirilmiştir. 30 dakika hata payına göre veriler % 90 oranında başarı sağlayabilecek şekilde sonuç alınmıştır.

(Mukherjee, Grabbe, & Sridhar, 2014)'ın “Meteorolojik koşullara dayalı havalimanında yer gecikme programı” adlı çalışmalarında, hava koşulları ve planlanan uçuş durumlarına göre gecikmelerin hesaplanmasına çalışılmıştır. Çalışmaya göre düşük görüş, şiddetli rüzgâr ve değişken hava koşulları uçuş zamanlarına etki etmektedir. GDP (Groud Desicion Program) yer gecikme hesaplama programı bu koşullarda ne kadar gecikme olacağını öngörmektedir. Bu makalede iki tane hava koşulu üzerinde durulmuştur. Bunlar görsel meteorolojik durumlar (Visual

Meteorological Conditions (VMC)) ve ölçülen meteorolojik koşullardır (The Instrument Meteorological Conditions (IMC)). Ölçülenden kasıt rüzgâr hızı, bulutluluk ve sis oranına gibi parametrelere göre hesaplanan hava durumu koşullarıdır.

Çalışmada Newark Liberty Uluslararası Havalimanı (EWR) ve San Francisco Uluslararası Havalimanı (SFO) arasındaki uçuş verileri ele alınmıştır. Hava koşullarının saatlik tahmini Rapid Update Cycle (RUC) 'dan ve trafik talepleri ise (gelecek yolcu sayısı) FAA's Aviation Systems Performance Metrics (ASPM) 'den elde edilmiştir. GDP'nin eğitim veri seti FAA's National Traffic Management Log (NTML)'den elde edilmiştir. Havalimanının IMC ve VMC'de yapabileceği operasyon kapasitesi ise FAA's Airport Capacity Benchmark raporlarından elde edilmiştir.

Çalışmada havalimanı durumu ve hava koşulları temel alarak makine öğrenmesine dayalı bir sistem geliştirilmeye çalışılmıştır. Tahmin için lojistik regresyon ve karar ağaçları kullanılmıştır. Her iki yöntemde makine öğrenme alanında denetimli bir öğrenme çeşididir. Sistemde temel olarak geçmiş saatlik veriler yardımıyla makine bu verileri öğrenir daha sonra elde edilen veri seti saatlik olarak sisteme verilir ve saat bazında çıkışlar elde edilir. Bu yapıda kullanılan lojistik regresyon modeli herhangi bir saatte hava ya da yer durumundaki olası durumu ifade etmektedir. Karar ağacı ise her bir grup tahmini için her bir sınıfa karşılık gelen yapıdır. Karar ağacı bütün verilerin yer aldığı ana düğüm ile başlar. Bu modele gelen veri seti kalibrasyon ve doğrulama olmak üzere iki ana parçaya ayrılır. Karar ağacı kalibrasyon verileri üzerinde işlem yapar. Eğitim setinde hava koşulu olarak sis yoğunluğu, rüzgâr hızı, bulutların yüksekliği parametre olarak alınmıştır. Bu veriler ışığında saatlik hava durumu etkisi ile hava trafik indeksi elde edilmiştir. Bunun yanında ortalama yolcu talepleri havalimanının kapasitesi oranında alınarak hesaplanmıştır.

Kullanılan eğitim verileri belirli bir hata payı olacağı düşünülerek kalibrasyona tabi tutulmuştur. Bunun sonucunda karar verme ağacındaki 491 ana ve 296 ara düğüm 91 ana 47 ara noda düşürülmüştür. Sonuç olarak test verisi üzerinde % 79 oranında bir tahmin seviyesine ulaşılabilmektedir.

ÜÇÜNCÜ BÖLÜM

MATERYAL VE YÖNTEM

3.1 Veri Seti

3.1.1 Veri Setinin Özellikleri

Veri setinde 2014 yılı içerisinde Esenboğa Uluslararası Havalimanı'na yapılan seferlerin iniş ve kalkış bilgileri ile havalimanındaki algılayıcılardan toparlanan meteorolojik ölçümler yer almaktadır. İniş kaydı olan uçuşlar için kalkış havalimanları ve kalkış koşulları yer almadığından değerlendirmeye alınmamıştır.

Tablo 3.1: Uçuş Bilgileri Veri Seti Örneği

Tarih	Çağrı Adı	U.Tipi	i/K Saati	Slot Tarihi	Slot Saati	Koltuk Sayısı	Tonaj	Uçuş Amacı
04.01.2014	AHY0004	A319	10:09	04.01.2014	10:00	122	74	110
08.01.2014	AHY0004	A319	10:13	08.01.2014	10:00	122	74	110
16.12.2014	THY7016	B738	21:48	16.12.2014	21:30	189.	75.	110
.

Tablo 3.1’de uçuş bilgilerinin bulunduğu bir kesit örneklendirilmiştir. Tablo 3.1’deki sütunların anlamları aşağıda verilmiştir:

- **Çağrı Adı:** Havalimanı tarafından her uçuşa verilen alfa-numerik bir değerdir.
- **Uçak Tipi:** Uçakların tipini gösteren alfa-numerik değerdir.
- **Tarih:** Uçağın gerçekte kalkış yaptığı tarihtir.

- **İ/K Saati:** Uçağın gerçekte kalkış yaptığı saat ve dakika bilgisidir.
- **Slot Tarihi:** Uçağın zamanlanmış kalkış tarihidir.
- **Slot Saati:** Uçağın zamanlanmış kalkış saat ve dakikasdır.
- **Uçuş Amacı:** Uçuşun hangi amaçla gerçekleştirildiğini bildiren numerik alandır.

Esenboğa Havalimanından alınan verilerde 2014 yılı içerisindeki toplam 45.479 kalkış gerçekleşmiştir. Veri seti içerisinde boş alan içeren kayıtlar çıkartıldığında 39.892 kalkış verisi kullanılmıştır. Bu kapsamda planlanan kalkış zamanında veya öncesinde gerçekleşen uçuşlar “Zamanında”, planlanan zamandan sonra gerçekleşen uçuşlar ise “Geciken” ismiyle etiketlenmiştir. Geciken uçuşlar için maksimum gecikme süresi yaklaşık 21 saattir.

Uçuş amaçlarını belirten detaylı liste Ek-C’de verilmiş olup 6 kategoride gruplanmıştır. Tablo 3.2’de görüldüğü gibi uçuş amaçlarının % 96.59’u yolcu kategorisindedir ve bu uçuşların % 93.36’sı geciken uçuş olarak etiketlenmiştir.

Tablo 3.2: Uçuş amacına göre etiketlerin dağılımı

Uçuş Amacı	Zamanında	Geciken
Yolcu	2.560	35.974
Kargo	6	8
Teknik	297	711
Genel	89	203
Askeri	2	40
Eğitim	1	1
Toplam	2.955	36.937

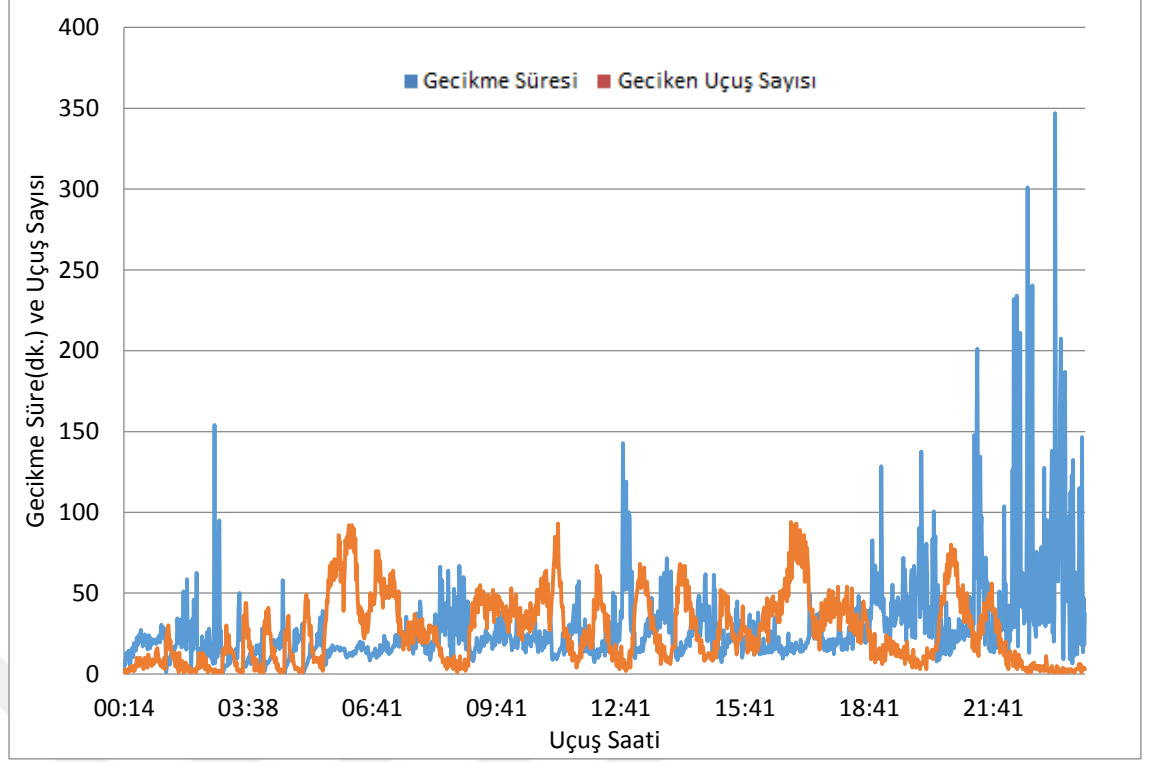
Temizlenmiş veri setindeki dağılım Tablo 3.3’te verilmiştir. Kış mevsimine göre yaz mevsimindeki uçuş sayılarında artış görülsede yaz mevsimindeki ortalama gecikme yüzdesi % 92.67 iken kış mevsimindeki gecikme yüzdesi % 93.10’dur. Bu oranlar ilkbaharda % 91.67 sonbahar da ise % 92.69’dur. Oranlar birbirine yakın olsa

da kış ve sonbahar mevsimlerindeki gecikmeli uçuşların yüzdesinin yaz ve ilkbahar mevsimlerine göre bir miktar daha fazla olduğu görülmüştür.

Tablo 3.3: Uçuşların Dağılımları

Aylar	Toplam Kalkış	Zamanında	Geciken	Gecikme Oranı (Geciken/TOPLAM) (%)
Ocak	3.387	203	3.184	94.00
Şubat	2.485	198	2.287	92.03
Mart	3.187	356	2.831	88.82
Nisan	3.319	210	3.109	93.67
Mayıs	3.436	257	3.179	92.52
Haziran	3.549	235	3.314	93.37
Temmuz	3.429	347	3.082	89.88
Ağustos	3.766	197	3.569	94.76
Eylül	3.530	222	3.308	93.71
Ekim	3.307	261	3.046	92.10
Kasım	3.193	247	2.946	92.26
Aralık	3.304	222	3.082	93.28
TOPLAM	39.892	2.955	36.937	-

Veri setine göre 2014 yılı içerisinde dakika bazlı olarak yıllık ortalama gecikme süresi ve geciken uçuş sayısını gösteren grafik Şekil 3.1’de gösterilmiştir.



Şekil 3.1: Gün içerisindeki her uçuş saati için yıllık ortalama gecikme süresi

Şekil 3.1 incelendiğinde kalkışlardaki gecikmelerin sayısı ile gecikme süresi arasında doğru bir orantı olmadığı görülmektedir. Örneğin geciken uçuş sayısının yıllık ortalamada çok düşük olduğu sabah 09:00 saatleri civarında gecikme süresinin ortalamada 1 saati, yine aynı şekilde saat 12:00 civarında geciken uçuş sayısı ortalamada çok düşük iken gecikme süresinin 2 saati bulunduğu görülmüştür. Benzer bir şekilde akşam 21:00-24:00 arası yıllık ortalama geciken uçuş sayısı 1-50 arasında değişirken ortalama gecikme süresinin 6 saate kadar çıktığı görülmektedir. Sanılanın aksine mesai giriş ve çıkış saat aralıklarında yaşanan yoğun trafikten dolayı uçuşlarda belirgin bir ortalama gecikme gözlemlenmemiştir.

Meteorolojik veriler Meteoroloji Genel Müdürlüğü'nün Esenboğa İstasyonu'ndan toplanmıştır. Her gün ilk ölçüm 00:50'de yapılmış ve ölçümler 1 saat aralıklarla tekrarlanmıştır.

3.1.2 Öznitelikler

Elde edilen ham veriden aşağıdaki öznitelikler seçilmiştir:

Uçuş/uçak öznelikleri:

- 1- **Uçaktaki yolcu koltuk sayısı:** 0 ile 505 arasında değişmektedir. Örneğin nakliye, kısa mesafe jet uçağı, eğitim uçaklarında yolcu koltuk sayısı 0 olarak belirtilmektedir.
- 2- **Uçağın ağırlığı (Tonaj):** 0 ile 447 ton arasında değişmektedir. Örneğin özel uçaklarda uçağın ağırlığı 0 olarak belirtilmiştir.
- 3- **Uçuş amacı:** Yolcu, kargo, teknik, genel, askeri ve eğitim kategorilerinde incelenmiştir.

Meteorolojik öznelikler:

- 1- **Basınç:** Belirli bir sıcaklık ve yoğunluktaki gazın birim yüzeye uyguladığı kuvveti ifade eder. Ölçüm birimi olarak Hpa (Hektopaskal) kullanılır. Hpa hava basıncı ölçü birimidir. 1 mb (Milibar)'a eşittir. Veri setindeki basınç değerleri 891.7 ile 919 arasında değişmektedir.
- 2- **QNH (Qualified Natural Horizon) Basınç:** Havalimanındaki hava basınç değeri Uluslararası Sivil Havacılık Organizasyonunun tanımladığı standart atmosfere göre ortalama deniz seviyesine indirilmesi sonucu bulunan değerdir. Rakım veya irtifayı ölçmekte kullanılan altimetre QNH değerine ayarlandığında uçağın veya havaalanının deniz seviyesinden olan irtifasını göstermektedir. Veri setindeki QNH basınç değerleri 999.5 ile 1,030 arasında değişmektedir.
- 3- **Bulut Kapalılığı (Okta):** Dikey görüşün ifade edilmesi açısından çok önemli bir tanımlama olup, 8 eşit parçaya bölüdüğü varsayılan semanın, ne kadarının bulutlar tarafından kaplandığının ifadesidir. 9 değeri de görüşün tamamen kapalı olduğunu belirtmektedir. Ölçüm birimi sayısal 0 ile 9 arasındaki tam sayıdır.
- 4- **Bulut Yüksekliği:** Bulutların görülüp izlenebildiği yüksekliğin yerden olan dikey mesafesi bulut taban yüksekliği olarak adlandırılmaktadır. Pratikte değişken olan birçok faktörün, sonucu direkt olarak etkilemesi nedeniyle bulut tabanının hesap edilmesi kolay değildir. Ayrıca bulut tabanı sabit değildir. Rüzgâr etkisiyle bulutlar dağınık veya parçalı görülebildikleri gibi hava akımlarının etkisiyle farklı yüksekliklerde de bulunabilirler. Ölçüm birimi feet'tir ve İngiliz birim sisteminde bir uzunluk


ölçüsü birimidir. 1 feet 30,48 cm uzunluktadır. Veri setindeki bulut yüksekliğinin değerleri 100 ile 4,000 arasında değişmektedir.

- 5- Görüş Mesafesi:** Gündüzleri aydınlatılmamış, geceleri ise aydınlatılmış uygun boyutları olan bir cismin, atmosferik koşullara bağlı olarak görülüp algılanabileceği en uzak mesafe olarak tanımlanmaktadır. Bu mesafe, her yönde aynı olmayabilir. Örnek vermek gerekirse, bulunduğu yerde doğuya baktığında 3.000 metre görüş tespit eden bir kişi, aynı noktadan batıya baktığında görüş değerini 2.000 metre olarak tespit edebilir. Önemli olan görüş mesafesi tespit edilirken hava aracı operasyonlarının yapılacağı bölgelerdeki durumu yansıtacak bilgilerin ortaya konulabilmesidir. Veri setindeki görüş mesafesinin değerleri 100 ile 4.000 arasında değişmektedir.
- 6- Nispi Nem:** Havanın içerisinde çözülmüş halde bulunan su buharı miktarının, havayı doyma noktasına getirmek için gerekli maksimum su miktarına oranıdır. Havacılıkta, havada bulunan nem miktarının yerine kullanılmasının sebebi, bağıl nemin, ortam sıcaklığına bağlı olarak, yoğuşmanın ne zaman başlayacağı hakkında bize bilgi sağlamasıdır. Bu bilgi için, üzerinde çalışılan hava kütleindeki nem miktarının önemli ölçüde değişmeyeceği kabul edilmektedir. 0 ile 100 arasındaki yüzdelik değer olarak ölçülür. Veri setindeki nem değerleri 9 ile 100 arasında değişmektedir.
- 7- Rüzgâr Hızı:** Rüzgâr hızı, atmosferdeki rüzgârın, hava veya diğer gazların hareket hızıdır. Hareket vektörünün büyüklüğü, skaler bir niceliktir. Veri setindeki ölçüm değerleri 0 ile 28 arasında değişmektedir.
- 8- Rüzgâr Yönü:** Rüzgârın yeryüzüne paralel hareket doğrultusunu ifade eder. Rüzgâr yönü genellikle ana ve ara yönlerde veya açısız azimut olarak ifade edilir. Veri setindeki rüzgâr yönü değerleri 0 ile 8 arasında değişmektedir.
- 9- Sıcaklık:** Gazın, ısınmaya bağlı olarak iç moleküler aktivitesinin ölçütüdür. Başka bir deyişle, gaz moleküllerinin ısı karşısındaki ortalama hareketlerinin (Moleküler titreşimler hariç), Santigrad (Celsius), fahrenheit ve mutlak sıcaklık (Kelvin) cinsinden ifadesidir. Havalimanındaki ölçümler Santigrad olarak verilmiştir. Veri setindeki sıcaklık değerleri - 9.3 ile 37.1 arasında değişmektedir.

Kullanılan özniteliklerin deęerleri normalleřtirme yapılarak belirli bir aralıęa indirgenmiřtir. Normalleřtirme, sınıflandırma ve kümeleme algoritmalarında kullanılan özniteliklerin birbirlerine göre büyüklüklerinin farklılıklar göstermesi nedeniyle, kullanılan özniteliklerin aynı ölçeęe indirgenmesi için kullanılır (Duda, Hart, & Stork, 2001). Minimum-maksimum ve ortalamaya göre normalleřtirme yöntemleri vardır. Çalışmamızda pozitif olan tüm öznitelikleri 0 ve 1 arasına, negatif olan öznitelikleri de -1 ve 1 arasına indirgemek için minimum-maksimum normalleřtirme yöntemi kullanılmıştır.

3.2 Uygulanan Metodoloji

Uçuřların kalkıř zamanlarındaki gecikme tahmininde kullanılan yöntemin akıř řeması Şekil 3.2’de verilmiştir. Çalışma kapsamında temel olarak verinin temizlenmesi, normalleřtirilmesi, öznitelik çıkarımı ve seçilmesi, verinin öğrenme ve test kümeleri olarak parçalanması ve YSA kullanarak tahmin modelinin öğrenilmesi gerçekleştirilmiştir. İleriki bölümlerde özniteliklerin seçilmesi, verinin öğrenme ve test kümeleri olarak parçalanması ve YSA kullanarak tahmin modelinin öğrenilmesi işlemlerinin detayları açıklanmıştır.



Şekil 3.2: YSA ile sınıflandırma akış diyagramı

3.2.1 Özellik Seçimi

Özellik seçimi, veri setinden, uygun bir öznitelik altkütmesi elde edilmesiyle hem doğru sınıflandırma oranı, hem de ölçeklenebilirlik bakımından daha iyi bir sınıflandırma modeli elde edilmesini sağlayan bir yöntemdir. (Onan & Korukoğlu, 2015), (Ünsalan & Erçil, 1998), (Guyon & Elisseeff, 2003), (Güneş & Polat, 2009).

Literatürde kullanılan çok sayıda özellik seçimi algoritması vardır. Bu çalışmada filtre özellik seçim algoritması kullanılmıştır. Filtre yöntemleri özellikleri seçmek için, kümeleme algoritması kullanmadan verinin bazı asıl özelliklerini seçer. Filtre yöntemlerinin özellik arama yöntemi ve özellik seçim kriteri olmak üzere iki temel bileşeni vardır (Liu & Motoda, 2007). Çalışmamızda iç-dış, tahmini mahalanobis mesafeleri toplamı ve Öklid mesafelerinin karelerinin toplamı özellik seçimi yöntemleri kullanılmış ancak iç-dış ile tahmini mahalanobis mesafeleri toplamı yöntemleri benzer davranış gösterdiğinden dolayı deneysel çalışmalarda tahmini mahalanobis mesafeleri toplamı kullanılmıştır. Kullanılan yöntemler aşağıda listelenmiştir.

- **İç-Dış Özellik Çıkarımı (in-in):** Veri seti kümelendikten sonra aynı kümede olan nesnelere arasındaki mesafelerin (İç mesafe) toplamını minimize ederken, farklı kümeler arasındaki mesafeleri (Dış mesafe) maksimize eder. Bu şekilde tüm özniteliklerin ayırt edici özellikleri daha keskin bir şekilde ortaya çıkaran bir özellik çıkarım yöntemidir.

$$\text{Inter_dist} = \min(\|c_i - c_j\|)^2$$

Denklem 3.1 İç Mesafe Fonksiyonu

Burada c_j kümenin merkezidir.

$$\text{Intra_dist} = \frac{1}{n} \sum_{j=1}^k \|x_i^j - c_j\|^2$$

Denklem 3.2 Dış Mesafe Fonksiyonu

Burada:

- K küme sayısı,

- c_j , j kümesinin matrisi,
- N parçacıkların sayısı,
- $\|x_i^j - c_j\|^2$ parçacıklar ve geometrik merkez arasındaki mesafedir.

- **Tahmini Mahalanobis Mesafeleri Toplamı (maha-s):** Sınıflandırmaya tabi tutulacak verilerin normal dağılımda olduğunu kabul eden ve eşitliklerde kovaryans matrisi kullanan ve iki nokta arasındaki uzaklığı bulan yöntemdir. Burada uzaklıkların toplamı bulunur.

S kovaryans matrisi ve ortalama $\mu = (\mu_1, \mu_2, \mu_3, \dots, \mu_N)^T$ gözlem dizisinden bir

$\chi = (\chi_1, \chi_2, \chi_3, \dots, \chi_N)^T$ gözleminin Mahalanobis mesafesi aşağıdaki gibi tanımlanır :

$$D_M(\chi) = \sqrt{(\chi - \mu)^T S^{-1} (\chi - \mu)}$$

Denklem 3.3 Mahalanobis Distances Fonksiyonu

Mahalanobis mesafe (Veya kare değeri için “genelleştirilmiş interpoint kare mesafesi”) aynı zamanda rastgele χ ve y iki vektör arasındaki ve kovaryans matrisi S ile aynı dağılımının bir benzerlik ölçüsü olarak da tanımlanabilir.

$$d(\chi, y) = \sqrt{(\chi - y)^T S^{-1} (\chi - y)}$$

Denklem 3.4 Mahalanobis Benzerlik Ölçütü

Eğer kovaryans matrisi birim matrisi ise, Mahalanobis mesafe Öklid mesafesine dönüşür. Eğer kovaryans matrisi diyagonal ise, daha sonra ortaya çıkan mesafe ölçüsü normalleştirilmiş Öklid mesafesi olarak adlandırılır:

$$d(x - y) = \sqrt{\sum_{i=1}^N \frac{(x_i - y_i)^2}{S_i}}$$

Denklem 3.5 Öklid Mesafe Ölçütü

S_i örnek kümesi üzerindeki x_i ve y_i 'in varyanslarıdır.

- **Öklid Mesafelerinin Karelerinin Toplamı (eucl-s)** : İki vektör arasındaki uzaklığı Pisagor bağıntısı ile bulan yöntemdir. Burada mesafelerin toplamı alınır.

$$d = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

Denklem 3.6 Pisagor Fonksiyonu

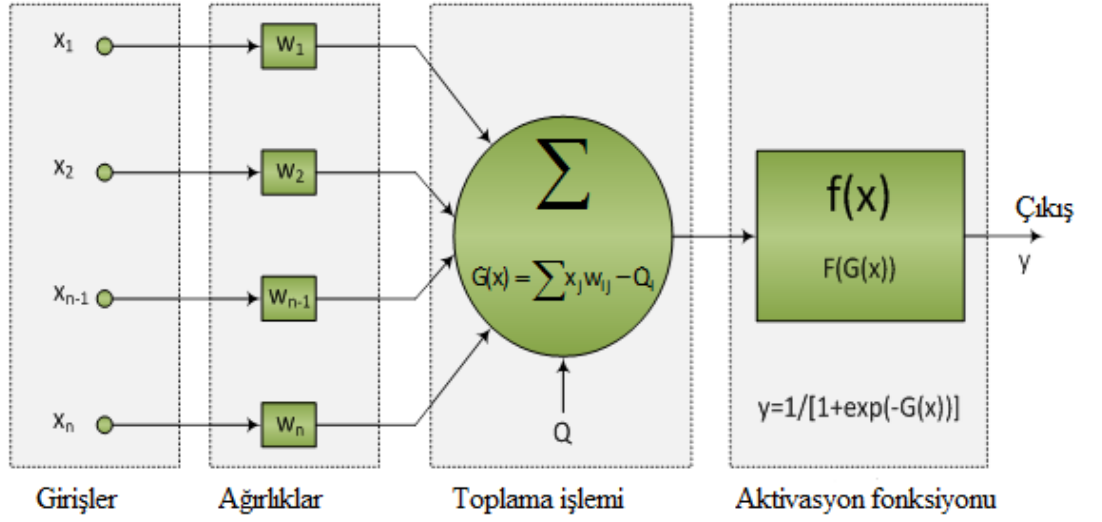
3.2.2 Yapay Sinir Ağları

Günümüz teknolojisinin gelişmesi ile beraber çok büyük miktarda dijital veri oluşmaya başlamıştır. Bu büyüklükteki verilerin elle işlenmesi ve analizinin yapılması mümkün değildir (Han & Kamber, 2001). Dolayısı ile büyük ölçekli veri içerisindeki gizli örüntülerin bulunmasında geleneksel yöntemlerin yetersiz kalması ile verinin daha iyi çözümlene yöntemleri ile işlenmesi gerekliliğini arttırmıştır. Makine öğrenmesi, matematiksel ve istatistiksel yöntemler kullanarak eldeki verilerden çıkarımlar yapan, bu çıkarımlarla bilinmeyene dair tahminlerde bulunan bir bilgisayar uygulama alanıdır. Makine öğrenmesi desen tanıma, sınıflandırma işlemleri, arama motorları, doğal dil işleme, finansal çözümlerler gibi günlük hayatın birçok alanında kullanılmaktadır. Makine öğrenmesinin alt çalışma alanlarından birisi de Yapay Sinir Ağlarıdır (YSA). YSA insan beyninin bilgi işleme tekniğinden esinlenerek geliştirilmiş bir bilgi işlem teknolojisidir. İnsanların düşünerek ve gözlem yaparak problemleri çözmesi altında yatan en önemli etkenin, insanın deneyimler yaşayarak öğrenme güdüsüdür. Öğrenme ve düşünmeyi sağlayan fizyolojik organ da beyindir.

YSA yöntemi de biyolojik sinir sistemi bulgularına dayanmaktadır (Bishop, 1995). Son yıllarda YSA, günümüz teknolojilerinin gelişmesi ile veri kaynaklarının ve işlem boyutların hızla arttığı bir dönemde karmaşık problemlerin çözümüne uygulanmış ve genel itibari ile başarılı sonuçlar alınmıştır. Özellikle bir sistemin ya da cihazın doğru çalışıp çalışmadığını öğrenmek için arıza analizi ve tespiti gibi uygulamalarda, protez tasarımı vb. gibi uygulamaları gerçekleştirebilmek için tıp alanında, silahların otomasyonu gibi uygulamalar için savunma sanayinde, görüntü ve veri sıkıştırma gibi uygulamalar için haberleşmede, ürün analizi ve tasarımı gibi konularda üretimde, uçaklarda otomatik pilot sistemleri gibi uygulamalar için ise otomasyon ve kontrol gibi alanlarda kullanılabilmektedirler (Subaşı, 2010). Literatürde beynin öğrenme ve düşünme özellikleri ön plana çıkarılarak, beyni oluşturan biyolojik hücrelerin (nöronların), matematiksel modellenmesi üzerinde yoğun çalışmalar yapılmıştır (Kaynak & Efe, 2000). YSA'lar insan beyninin fonksiyonel özelliklerine benzer yapısıyla teorik uygulamaların ötesinde günlük hayatta finansal mühendisliğe, tıptan iletişime kadar birçok alanda kullanılmaktadır (Öztemel, 2003). Bu alanlardan bazıları şunlardır: Veri madenciliği, optik karakter tanıma, banka kredi destek sistemi, zeki araçlar ve robotik sistemler, radar ve sonar sinyal sınıflandırma, kan hücre reaksiyonları ve kan analizlerini sınıflandırma, kanser tespiti, kalite kontrolü, ürün pazar performans tahmini, beyin modelleme çalışmalarıdır.

3.2.2.1 Yapay Sinir Hücresinin Yapısı

Yapay sinir sisteminde, ağları oluşturmak için çeşitli şekillerde bir araya getirilen sinir hücreleri bulunmaktadır. Bunlara nöron adı verilir. YSA temel olarak giriş katmanı, katmanları arası (Gizli katmanlar) ve çıkış katmanından oluşur. Giriş katmanı dış dünyadan gelen verileri alır. Çıkış katmanı kullanıcıya ağın sonucunu sunmaktadır. Bu iki katman arasındaki gizli katmanlar verinin işlendiği yerdir. Gizli katmandaki sinir hücrelerinin sayısı, performansın yanı sıra ağ uzunluğu için de önemlidir. Genellikle her bir nöronun çıkışı bir sigmoid veya hiperbolik tanjant olarak doğrusal olmayan bir aktivasyon fonksiyonu kullanılarak belirlenir. Ağda bilinmeyen bir girdi uygulandığında YSA, geçmiş deneylerden genelleme yapabilir ve yeni bir sonuç üretebilir (Fausett, 1994). Sinir ağının çıkışı denklem tarafından belirlenir. Şekil 3.3 temsili bir yapay sinir hücresini göstermektedir.



Şekil 3.3: Yapay Sinir Hücresi Modeli

Şekil 3.3 'deki yapay sinir hücresi modelinde aşağıdaki bölümler yer almaktadır:

- **Girişler:** X ile gösterilen ve dış dünyadan ya da bir önceki katmandan alınıp yapay sinir hücrelerine verilen değerlerdir.
- **Ağırlıklar:** W ile gösterilen ağırlıklar bir sinir hücresine gelen bilginin etkisini gösterir.
- **Toplama İşlemi:** Her bir hücreye gelen net girdiler bu fonksiyon aracılığı ile hesaplanır.

$$z_i = \sum_{i=1}^n (w_{ij}x_i + b_j)$$

Denklem 3.7 YSA için Net Girdi Fonksiyonu

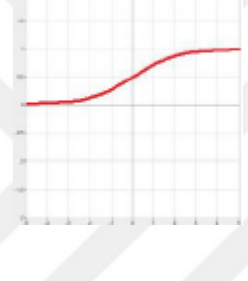
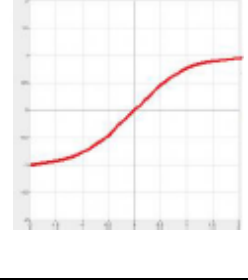
Toplam fonksiyonu sonucunda elde edilen değer, doğrusal ya da doğrusal olmayan türevlenebilir bir aktivasyon fonksiyonundan geçirilerek çıktı hesaplanır.

$$y = f(z_i) = f(\sum_{i=1}^n (w_{ij}x_i + b_j))$$

Denklem 3.8 YSA Çalıştırıldıktan Sonra Elde Edilen Çıktının Matematiksel Tanımı

- **Aktivasyon Fonksiyonu:** Aktivasyon fonksiyonu giriş ve çıkış arasındaki eğrisel eşleşmeyi sağlar. Literatürde kullanılan çeşitli aktivasyon fonksiyonları vardır (Öztemel, 2003). Çalışmamızda Tanjant Hiperbolik Aktivasyon Fonksiyonu ve Logaritmik Sigmoid Aktivasyon Fonksiyonu kullanılmıştır. Bu iki fonksiyon ve matematiksel ifadeleri Tablo 3.4’de gösterilmiştir.

Tablo 3.4: Uçuş gecikme tahmini modellenen YSA’da kullanılan aktivasyon fonksiyonları

Sigmoid Aktivasyon Fonksiyonu		$F(\text{Net}) = \frac{1}{1 + e^{-\text{Net}}}$	Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir.
Tanjant Hiperbolik Aktivasyon Fonksiyonu		$F(\text{Net}) = \frac{e^{\text{Net}} + e^{-\text{Net}}}{e^{\text{Net}} - e^{-\text{Net}}}$	Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonuna benzer bir fonksiyondur. Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken hiperbolik tanjant fonksiyonunun çıkış değerleri -1 ile 1 arasında değişmektedir.

Tanjant Hiperbolik Aktivasyon Fonksiyonu ile Logaritmik Sigmoid Aktivasyon Fonksiyonunun matematiksel tanımları aşağıdaki gibidir.

$$2/(1 + \exp(-2 * n)) - 1$$

Denklem 3.9 Tansig Fonksiyonunun Matematiksel İfadesi

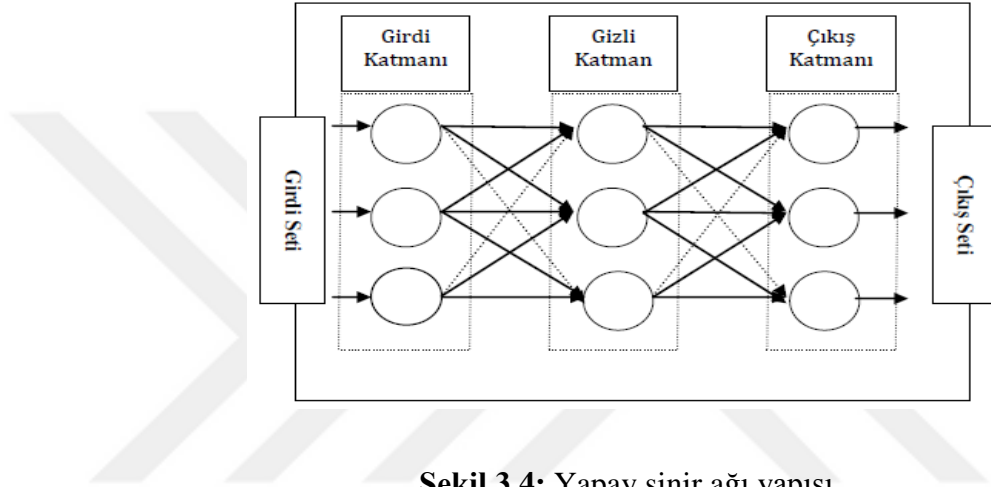
$$\text{logsig}(n) = 1 / (1 + \exp(-n))$$

Denklem 3.10 Logsig Fonksiyonunun Matematiksel İfadesi

- **Çıkış:** İlgili fonksiyonların çalışmasından sonra üretilen çıktıdır.

3.2.2.2 Yapay Sinir Ağı'nın Yapısı


YSA girdi ve çıktı katmanlarından oluşabileceği gibi ayrıca bir ya da birden fazla ara katmana da sahip olabilir. Elbette ki ara katmansız bir YSA karmaşık problemlerin çözümünde yetersiz kalacaktır. Bu problemi çözmek için çok katmanlı YSA'lar kullanılır. Çok katmanlı YSA'larda bir veya birden fazla giriş, yine aynı şekilde bir veya birden fazla ara katman ve ara katmanlarda modelin yapısına göre nöronlar ve yine bir ya da birden fazla çıktı katmanı bulunabilir. Çok katmanlı bir YSA modeli Şekil 3.4'de gösterilmiştir.




Şekil 3.4: Yapay sinir ağı yapısı

YSA, yapay nöronların düğüm ve ağırlıklı yönlü kenarların nöron girişleri ve nöron çıkışları arasındaki bağlantı olduğu ağırlıklı yönlü çizge olarak da düşünülebilir. Bağlantı mimarilerine bağlı olarak YSA iki kategoriye ayrılabilir (Ayas, 2014):

- **İleri beslemeli YSA:** Döngü olmayan çizgelerdir.
- **Geri beslemeli YSA:** Geri besleme bağlantılarından dolayı döngülerin meydana geldiği çizgelerdir. Şekil 3.5 ve Şekil 3.6'da İleri ve Geri Beslemeli Ağ Yapıları gösterilmiştir.



Şekil 3.5: İleri beslemeli YSA modeli



Şekil 3.6: Geri beslemeli YSA modeli

Bir YSA tasarlarırken katman sayısı, katman başına düşen nöron sayısı ve eğitim tekrarlamaları, öğrenme hızı ve aktivasyon fonksiyonu sayısı gibi karar verilmesi gereken birçok farklı parametre vardır. Bu parametrelerin her birisi ağıın öğrenme başarısını etkilemektedir. Ancak gizli katmanda bulunan nöronlar doğrusal olmayan davranışları nedeniyle, YSA'nın toplam davranışındaki doğrusal olmama özelliğini sağlarlar. Giriş ve çıkış katmanındaki nöron sayısı probleme göre belirlenirken, gizli katmandaki nöron sayısını veren herhangi bir analitik yöntem yoktur (Kaynak & Efe, 2000). Bu sebeple sinir ağlarında kaç tane gizli katman kullanılacağı ve her bir gizli katmanda kaç nöron olacağı bugüne kadar belirlenememiştir, probleme göre değişen bu nitelikler deneme-yanılma yoluyla bulunur (Topal, 2010).

3.2.3 Doğrulama Yöntemi

Doğrulama, öğrenme ağlarında eğitim ve test verisi ile beraber kullanılarak ağın ne kadar başarı ile öğrenme işlemini gerçekleştirdiğini belirlemek için kullanılır. En çok tercih edilen yöntemlerden birisi bölüm 3.2.3.1’de anlatılan çapraz doğrulamadır. Gerçekleştirilen uygulamada çapraz doğrulama yöntemi kullanılmakla beraber, veri setinin dengesiz dağılımından dolayı, aşırı öğrenme durumu ve başarımı net görebilmek için kayan pencere yöntemi kullanılarak eğitim verisi oran olarak dengeli hale getirilmiştir. Kayan pencere yöntemi Bölüm 3.2.3.2’de, deneysel çalışma sonuçları ise Bölüm 4.1.3’te anlatılmıştır.

3.2.3.1 Çapraz Doğrulama

Sınıflandırıcılara verilen girişler tür olarak ikiye ayrılmaktadır. Bunlardan birisi modellenen sınıflandırıcının eğitilmesi için kullanılan eğitim verisi diğeri ise eğitilen modelin başarısını ölçmek için kullanılan test verisidir (Duda, Hart, & Stork, 2001). Eğitim ve test verisinin seçimi sınıflandırıcının başarısını doğrudan etkilemektedir. Çünkü sınıflandırıcı eğitim verisine göre öğrenir ve gelen test verisine göre de başarımı ölçer. Verinin ne kadarının ve hangilerinin eğitim ve test verisi olarak kullanılacağını belirleyen yöntem olarak geliştirilen çapraz doğrulama tüm verinin eğitim ve test olarak kullanılmasına olanak sağlar. Çapraz doğrulama, veri setini sınıflandırıcının model parametrelerinin belirlenmesinde kullanılan eğitim seti ve eğitilen sınıflandırıcının başarımlarını ölçmek için kullanılan test seti olarak ikiye ayıran yöntemdir. (Duda vd. 2000). Genel olarak k-parçalı doğrulama yöntemi kullanılır. Toplam n örneğin bulunduğu bir veri setinde, her birinde n/k örneğin bulunduğu k adet ayrık parçaya ayrılır. Her seferinde farklı bir veri seti kümesi test için ayrılarak kalan diğer $k-1$ veri seti eğitim için kullanılır. Her defasında test kümesi değiştirilerek sınıflandırıcı k defa eğitilir. Bu şekilde elde edilen k adet hatanın ortalaması ile sınıflandırıcı performansı tahmin edilmiş olur (Narin, İşler, & Özer, 2014).

Bölüm 4.1.3’te anlatıldığı gibi uçuş gecikmeleri için modellenen YSA’da, verinin % 80’ni eğitim % 20’si test verisi olarak kullanılmıştır.

3.2.3.2 Kayan Pencere Yöntemi

Veri setindeki farklı türlerin oran olarak çok farklılık gösterdiği durumlarda çalışmaların başarı oranları belirgin olarak görülemeyebilir. Böyle bir durumda sınıflandırma için kullanılacak öğrenme algoritmaları aşırı öğrenme gibi olumsuzluklarla karşılaşabilmektedirler. Bu sorunun çözümü için tarafımızdan kayan pencere yöntemi geliştirilmiştir. Öğrenme algoritması çalıştırılırken veri seti farklı varyasyonlarla birden fazla çalıştırılarak her yinelemede elde edilen sonuçların ortalaması ile başarımlar elde edilir. Veri setinde farklı türde veriler olabilir. Böyle bir veri setinde öğrenme algoritmalarının verimli çalışmasını sağlamak için eğitim verisinin dengeli dağılımda olması önemlidir. Kayan pencere yöntemi sayesinde sınıflandırılması yapılacak veri türleri her yineleme için eşit dağılımda alınarak eğitim seti oran olarak dengeli hale getirilebilir. Bu çalışmada kullanılan veri setinin % 93'lük oranı ile büyük bölümünü oluşturan geciken uçuşlarla, zamanında gerçekleşen uçuşlar her yineleme için eşit oranda alınarak eğitim seti oluşturulmuş ve YSA eğitilmiştir.

3.3 Çalışmada Kullanılan Araç, Gereç ve Ortam

Uygulanması düşünülen yöntem ve algoritmalar Matlab programlama dilinde gerçekleştirilmiştir. Matlab, MathWorks tarafından geliştirilen ve kullanıcıya, matris işleme, fonksiyon ve veri çizme, algoritma uygulama, kullanıcı ara yüzü oluşturma, C, C++, Java ve Fortran gibi diğer dillerde yazılmış programlarla ara bağlama imkânı tanıyan dördüncü nesil bir programlama dilidir (Guyon & Elisseeff, 2003). Ayrıca Matlab programı kullanılarak çok sayıda çalışmanın yapılmış olması, kolay kod geliştirilmesi ve internet üzerinde geliştiricisi olan www.mathworks.com'un yanı sıra çok sayıda kod desteğinin alınacağı web sitelerinin bulunması da çalışmamızda Matlab programını tercih etme sebeplerindedir. Kod yazım aşamasında bahsi geçen algoritmalar Matlab araç kutusundaki metotlar aracılığı ile gerçekleştirilmiştir. Ayrıca özellik seçimi işlemini yapmak için genellikle desen tanıma işlemleri için geliştirilmiş olan PRTOOL adında bir Matlab araç kutusu kullanılmıştır (PRTOOL,2015).

DÖRDÜNCÜ BÖLÜM

DENEYSEL ÇALIŞMALAR VE SONUÇLAR

4.1 Kullanılan Algoritma ve Yaklaşımlar

Bu çalışmada çeşitli analiz aşamalarından geçirilerek öğrenme algoritmasının kullanımına hazır hale getirilen veri seti, Matlab'ta YSA'nın kullanacağı şekilde oluşturulmuştur. Öncelikle normalleştirme işlemi uygulanmış ve özellik seçimi ile özneliklerin ilgi sırası belirlenmiştir. YSA'da, ağ giriş ve çıkışlarına belirli ön işlem adımları uygulayarak yapay sinir ağına sunulan verilerin eğitimi daha verimli hale getirilebilir. Normalleştirme de bu ön işlemlerden birisidir. Normalleştirilmemiş veri seti ile bir ağı eğitmek hem ağın eğitim süresini uzatacak hem de ağın verimini düşürecektir. Normalleştirme işlemlerinde farklı teknikler kullanılmakla beraber çalışmamızda minimum-maksimum kuralı kullanılarak veri seti belirli bir aralığa indirgenmiştir. Ardından en uygun YSA yapısı için bazı uygulamalar yazılmıştır. Son olarak tasarlanan YSA modeli çalıştırılmış ve sonuçları doğrulamak için çapraz doğrulama yöntemi uygulayarak sonuçlar alınmıştır.

4.1.1 Özellik Seçimi

Özelliklerin ilgi sırasının belirlenmesi için Bölüm 3.2.1'de anlatılan algoritmalar kullanılmış ve Tablo 4.1'de gösterildiği gibi algoritmaların çalıştırılması sonucunda elde edilen ilgi sıraları elde edilmiştir. Kullanılan algoritmalar aşağıda listelenmiştir.

- İç-dış özellik çıkarımı (in-in)
- Tahmini Mahalanobis mesafeleri toplamı (maha-s)
- Öklid mesafelerinin karelerinin toplamı (eucl-s)

Tablo 4.1: Elde edilen özellik sıraları

İlgi Sırası	İn-in	maha-s	eucl-s
1	Uçuş amacı	Uçuş amacı	Bulut yüksekliği
2	Koltuk sayısı	Koltuk sayısı	Rüzgâr yönü
3	Tonaj	Tonaj	Bulut kapalılığı
4	Rüzgâr hızı	Rüzgâr hızı	Sıcaklık
5	Sıcaklık	Sıcaklık	Nem
6	Bulut yüksekliği	Bulut yüksekliği	Uçuş amacı
7	Bulut kapalılığı	Bulut kapalılığı	Koltuk sayısı
8	Görünürlük	Görünürlük	Görünürlük
9	Rüzgâr yönü	Rüzgâr yönü	Rüzgâr hızı
10	Nem	Nem	Tonaj
11	Basınç	Basınç	Basınç
12	QNH-basınç	QNH-basınç	QNH-basınç

Tablo 4.1’de görüldüğü gibi, iç-dış özellik çıkarımı ve tahmini Mahalanobis mesafeleri toplamı algoritmaları benzer davranış göstermektedirler. Bu sebeple ileriki bölümlerde YSA’yı modellerken özellik seçimi olarak bu iki algortmadan sadece tahmini Mahalanobis mesafeleri toplamı yöntemi kullanılmıştır. Ayrıca kullandıkları mesafe ölçüm algoritmalarının farklılığından dolayı Öklid mesafelerinin karelerinin toplamı ile tahmini Mahalanobis mesafeleri toplamı yöntemlerinin özelliklerin ilgi sıralaması sonuçlarında farklılık görülmekle beraber her üç yöntemde de ortak olarak basınç özniteliklerinin etki düzeyinin en az olduğu görülmektedir.

4.1.2 Uygun YSA Yapısının Belirlenmesi

Genel olarak bir YSA modellerken uygulanması gereken adımlar aşağıdaki gibidir:

- 1- Veri Analizi
- 2- Normalleştirme
- 3- Öznitelik Seçimi
- 4- Eğitim ve Test Verilerinin Seçilmesi
- 5- Ağın Oluşturulması ve Parametrelerinin Seçilmesi

- 6- Ađın Eđitim Verileri ile Eđitilmesi
- 7- Ađın Test Verileri ile Test Edilmesi
- 8- Sonuların Dođrulanması

Arařtırmalarımıza gre her probleme gre uygulanacak YSA modeli farklıdır. zellikle gizli katmandaki katman ve her katmandaki nron sayısı, kullanılacak eđitim ve aktivasyon fonksiyonlarının seimi iin literatrde herhangi bir řekilde belirlenmiř bir yntem yoktur. Bu sebeple mevcut veri yapısına uyan en iyi YSA modelini bulmak iin mmkn olan seviyede birok farklı parametreyi deneyecek bir Matlab uygulaması yazılmıřtır. Gizli katmandaki nron sayısının belirlenmesinde st sınır olarak ařađıdaki kurallara dikkat edilmiřtir (Karsoliya, 2012) .

- 1- Gizli katmandaki nronların sayısı, giriř katmanı boyutunun $2/3$ ' kadar (% 90 veya % 70 oranında) olmalıdır. Bu yetersiz ise ıkıř tabakası nronları, daha sonra ilave edilebilir.
- 2- Gizli katmandaki nron sayısı giriř katmanındaki nron sayısının iki katından az olmalıdır.
- 3- Gizli katmandaki nronların boyutu, giriř katmanının boyutu ile ıkıř katmanının boyutu arasında olmalıdır.

En uygun YSA yapısını belirlemek iin yazılan uygulama ncelikle tek katmanlı geri beslemeli bir YSA modeli zerinde alıřtırılmıřtır. Bu kapsamda uygulamanın dng sayısını da oluřturan parametrelerin maksimum deđerleri ařađıdaki gibi kullanılmıřtır:

- Kullanılan zellik Seme Sayısı = 2
 - Tahmini Mahalanobis mesafeleri toplamı
 - klid mesafelerinin karelerinin toplamı
- zellik sayısı = 12
 - Uaktaki koltuk sayısı
 - Uađın ađırlıđı (tonaj)
 - Uuř amacı
 - Bu zelliklere ek olarak uuř anındaki havalimanından llen:
 - Basın
 - QNH basın

- Bulut kapalılığı
- Bulut yüksekliği
- Görüş mesafesi
- Nem
- Rüzgâr hızı
- Rüzgâr yönü
- Sıcaklık
- Katman başına nöron sayısı = 50
- Transfer fonksiyonu sayısı = 2
 - Tanjant sigmoid transfer fonksiyonu
 - Logaritmik sigmoid transfer fonksiyonu
- Eğitim fonksiyonu sayısı = 14
 - Levenberg-Marquardt geri yayılım eğitim fonksiyonu
 - Bayes regülarizasyon geri yayılım eğitim fonksiyonu
 - BFGS quasi-Newton geri yayılım eğitim fonksiyonu
 - Powell-Beale yeniden başlatma ile eşlenik gradyan geri yayılım eğitim fonksiyonu
 - Polak-Ribiere güncellemeleri ile eşlenik gradyan geri yayılım eğitim fonksiyonu
 - Eğim düşümü geri yayılım eğitim fonksiyonu
 - Geri yayımlı uyarlanabilir öğrenme oranı ile eğim düşümü eğitim fonksiyonu
 - İvme geri yayılımı ile eğim düşümü eğitim fonksiyonu
 - Geri yayımlı ivmeli ve uyarlanabilir öğrenme oranı ile eğim düşümü eğitim fonksiyonu
 - Bir adımlı daireyi iki noktadan kesen geri yayılım eğitim fonksiyonu
 - Esnek geri yayılım eğitim fonksiyonu
 - Ölçeklendirilmiş eşlenik gradyan geri yayılım eğitim fonksiyonu
 - Ağırlık ve eğilimli öğrenme kuralları ile yığın eğitim fonksiyonu
 - Periyodik sıralı ağırlık/eğilim eğitim fonksiyonu

- Öğrenme fonksiyonları ile rastgele sıralı artan eğitim fonksiyonu
- Performans fonksiyonu sayısı = 3
 - Ortalama mutlak hata performans fonksiyonu (mae)
 - Ortalama hata kareleri toplamı performans fonksiyonu (mse)
 - Ortalama hata kareleri toplamı regülerizasyon performans fonksiyonu (msereg)

Bu uygulama sayesinde tek katmanlı bir YSA yapısı için en yüksek başarı oranını sağlayan parametreler tespit edilmeye çalışılmıştır. Bu programın çalışma süresi yaklaşık 5 gün sürmüş ve mevcut program, parametrelerin çok olması, matematiksel işlemlerin ve süresinin fazlalığından dolayı çok katmanlı YSA modeli üzerinde çalıştırılamamıştır. Ancak tek katmanlıdan elde edilen verilerle iki ve üç katmanlı da denenmiştir. Elde edilen 196.560 sonuçtan % 77 ve üzeri başarı sağlayan parametreler Tablo 4.2’de, % 75 ve üzeri başarılı olanlar ise Ek B’de, parametre açıklamaları ise Ek D’de sunulmuştur.

Tablo 4.2: Tek katmanlı YSA’da farklı parametreler için başarı oranları

Özellik Seçimi Fonk.	Giriş Sayısı	Transfer Fonk.	Nöron Sayısı	Eğitim Fonk.	Performans Fonk.	Başarı %
maha-s	8	tansig	24	trainlm	mse	80
maha-s	8	tansig	22	trainbr	mse	79
maha-s	7	logsig	28	trainlm	mse	78
maha-s	12	tansig	29	trainbr	msereg	78
eucl-s	7	logsig	22	trainlm	mae	77
maha-s	11	logsig	17	trainbr	msereg	77
maha-s	12	logsig	25	trainbr	mae	77

Sonuçlar incelendiğinde tek katmanlı için 20 nöron ve üzeri, eğitim fonksiyonu olarak Levenberg-Marquardt geri yayılım (trainlm) ve Bayes regülarizasyon geri yayılım (trainbr) algoritmaları, performans fonksiyonu olarak da ortalama hata kareleri toplamı (mse) kullanıldığında başarı oranının daha yüksek çıktığı gözlemlenmiştir. Elde edilen bu sonuçlar ile problemimize uygun YSA modellemesi gerçekleştirilmiştir. Kullanılan fonksiyonların açıklamaları aşağıda verilmiştir.

Levenberg-Marquardt Eğitim Fonksiyonu: Ağırlık ve eğilim değerlerini güncelleyen bir ağ eğitim fonksiyonudur. Aynı zamanda Levenberg-Marquardt geri yayılım algoritması Matlab araç kutusunda en hızlı geri yayılım algoritmasıdır ve diğer algoritmalarından daha fazla bellek tüketmesine rağmen bir ilk seçim denetimli algoritması olarak sıklıkla kullanılmakta olan popüler bir eğitim fonksiyonudur.

Bayes Regülarizasyon Eğitim Fonksiyonu: Levenberg-Marquardt optimizasyona göre ağırlık ve eğilim değerlerini güncelleştiren bir ağ eğitim işlevidir. Hataların karesini ve ağırlıklarını en aza indirir ve de genelleştirilmiş bir ağ oluşturacak şekilde daha sonra doğru kombinasyonu belirler.

Mean Square Error (Ortalama Kareler Hatası) : İki sinyal vektörü arasındaki benzerliği ölçmek için kullanılan bir nicelik ölçütüdür. Ortalama kareler hatası ne kadar az ise benzerlik o kadar fazladır.

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} = \frac{\sum \text{tahmin hataları}^2}{n}$$

Denklem 4.1 Ortalama Kareler Hatasının Matematiksel İfadesi

Mean Absolute Error (Ortalama Mutlak Hata): Sonuçlara ne kadar yakın tahmin yapıldığını ölçmeye yarayan bir istatistikî yöntemdir. Matematiksel ifadesi aşağıdaki gibidir. Burada f tahmin değeri y gerçek değerdir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| = \frac{1}{n} \sum_{i=1}^n |e_i|$$

Denklem 4.2 Ortalama mutlak hatanın matematiksel ifadesi

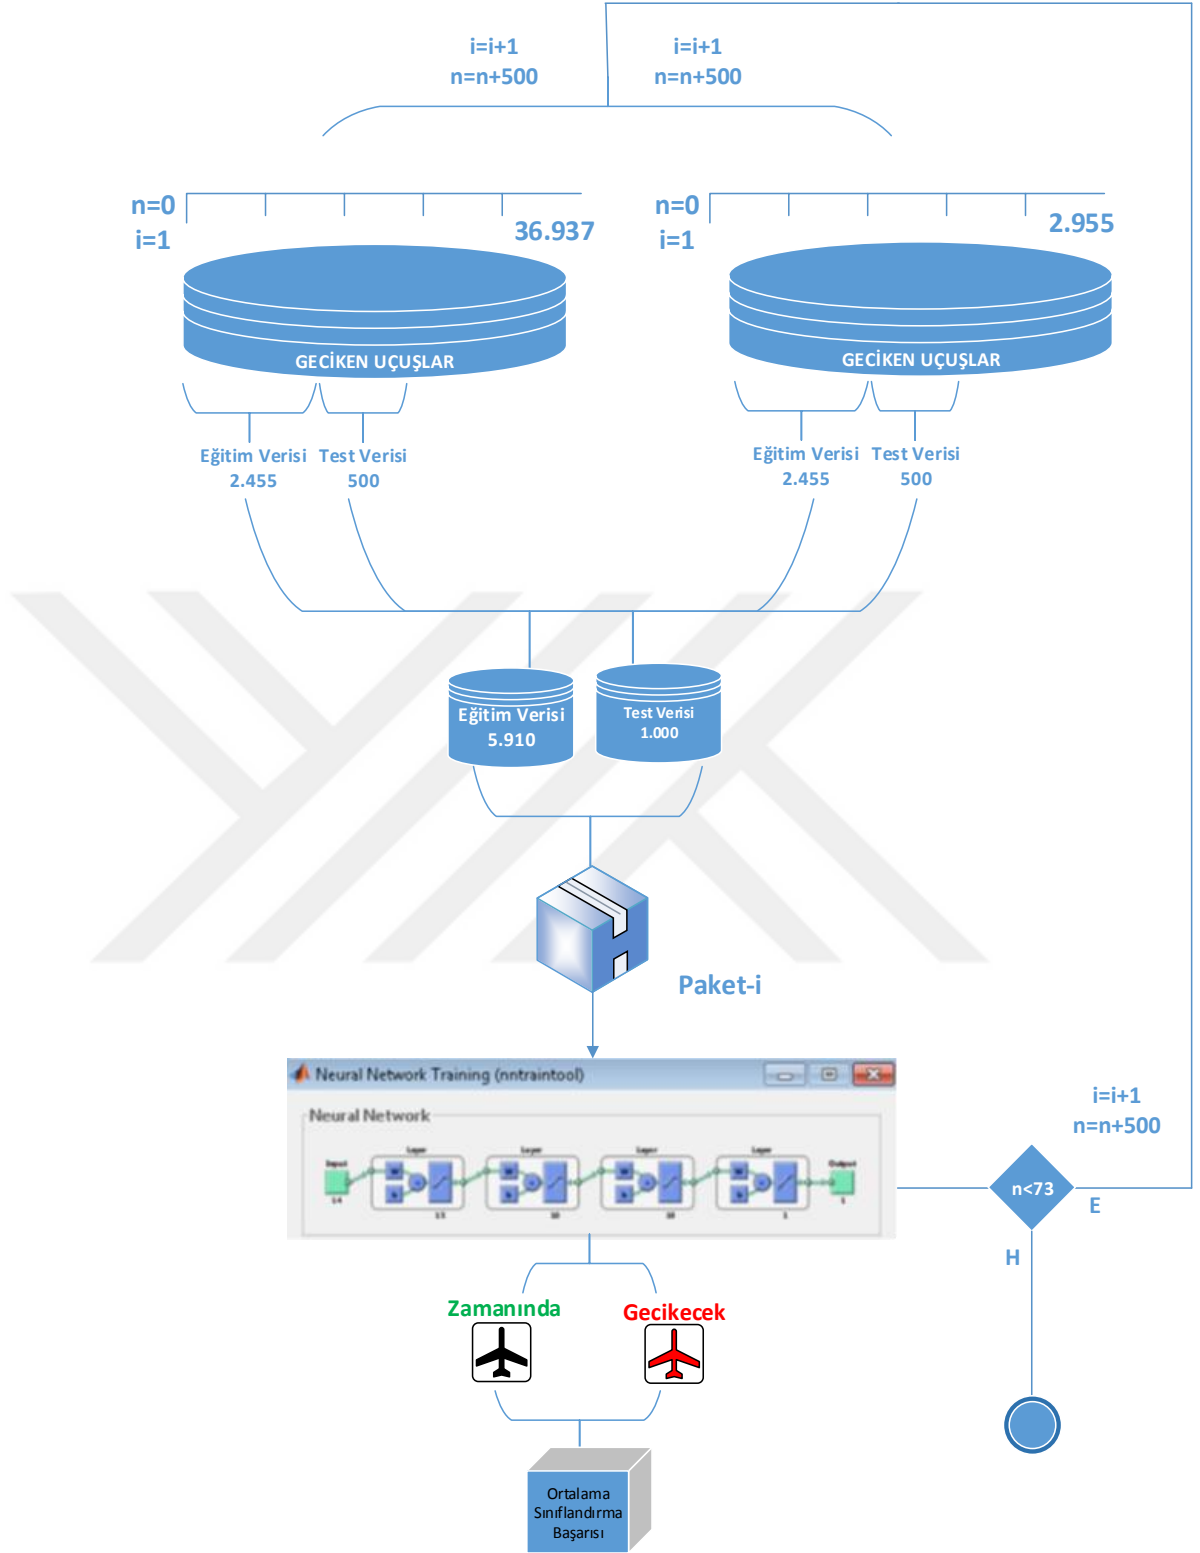
Mean Squared Error W/Reg Performans Fonksiyonu: Ortalama kareler hatası ve ağırlık ve eğilim değerlerinin karelerinin ortalamasının ağırlık toplamları olarak ağ performansını ölçen fonksiyondur.

4.1.3 YSA'nın Çalıştırılması

Bölüm 4.1.2'de anlatılan programın çalıştırılması sonucunda elde edilen verilere göre eğitim fonksiyonu olarak Levenberg-Marquardt geri yayılım algoritması kullanılmıştır. Matlab araç kutusunda bu algoritmanın komutu "trainlm"dir. Bu fonksiyon, Levenberg-Marquardt optimizasyonuna göre ağırlık ve eğilim değerlerini güncelleyen bir ağ eğitim fonksiyonudur. Aynı zamanda Levenberg-Marquardt geri yayılım algoritması Matlab araç kutusunda en hızlı geri yayılım algoritmasıdır ve diğer algoritmalarından daha fazla bellek tüketmesine rağmen bir ilk seçim denetimli algoritması olarak sıklıkla kullanılmakta olan popüler bir eğitim fonksiyonudur. (MathWorks, 2015).

Aktivasyon fonksiyonu olarak hem uygun YSA yapısı araştırılırken elde edilen bulgulara göre hem de veriler negatif değerlere de yakınsadığından Tanjant hiperbolik aktivasyon fonksiyonu kullanılmıştır. Bu fonksiyonunun çıkış değerleri -1 ile 1 arasında değişmektedir.

Elimizdeki veri setinin karakteristiği gereği, geciken kalkışların oranı tüm verinin yaklaşık % 93'ünü oluşturduğu halde, % 80 eğitim, % 20 test verisi olacak şekilde çapraz doğrulama uygulayarak uçuş gecikmesi için modellenen YSA eğitildiğinde, sınıflandırmadaki başarı oranının ortalama % 92.73 olduğu gözlemlenmiştir. Ancak verilerin mevcut dağılımı ile ağın öğrenme değil, belli bir tekrarlardan sonra aşırı yüklenme durumu yüksek bir olasılıktır. Bu problemi aşmak için eğitim ve test verisinin her yineleme için eşit oranda YSA'ya verilmesi kararı alınmış ve bu sebeple Şekil 4.1'de gösterilen kayan pencere yöntemi geliştirilmiştir.



Şekil 4.1: Veri setindeki dengesiz dağılım problemi için geliştirilen kayan pencere yöntemi

Şekil 4.1’de görselleştirilen yöntemle göre veri setinde oransal olarak daha az bulunan zamanındaki uçuşlar temel alınarak eğitim ve test verilerinin eşit oranda alınabilmesi sağlanmıştır. Bu kapsamda öncelikle veri seti zamanında ve geciken olarak ikiye parçalanmış ve geciken kalkışların sayısı 36.937 zamanında gerçekleşen uçuşların sayısı ise 2.955 olacak şekilde iki ayrı veri seti oluşturulmuştur. Zamanında gerçekleşen toplam kalkış sayısı 2.955 olduğu için, her yinelemede bu verinin 2.455 adeti eğitim geri kalan 500 adeti ise test verisi olarak kullanılmıştır. Eğitim ve .test verilerini geciken ve zamanında olan uçuşlar için eşit oranda kullanma durumundan dolayı aynı sayıdaki eğitim ve test sayısı da geciken uçuşlar için alınmıştır. Bu durumda her yineleme için adet olarak yarı yarıya olmak üzere toplamda 5.910 adet eğitim verisi ve 1.000 adette test verisi elde edilmiştir. Ancak uçuş gecikme tahmini için tasarlanan YSA’ya bu şekilde 36.937 adet geciken uçuştan toplamda 2.955 adeti eğitim ve test verisi olarak verilmek zorunda kalınmıştır. Yani 33.982 adet geciken kalkış verisi kullanılamamıştır. Geciken verinin geri kalan kısmının da kullanılabilmesi için paket mantığı geliştirilerek bu sorun aşılmaya çalışılmıştır. Test verisi olarak 500’er adet veri kullanıldığı için toplam geciken kalkış sayısı olan 36.937 uçuş verisinin de tamamının test verisi olarak kullanılabilmesi adına veri seti paketlere bölünerek YSA’ya verilmiş her paket işlemi bittikten sonra hem geciken hem de zamanındaki veri seti 500’er adet kaydırılmak sureti ile yeni paketler elde edilmiştir. Elde edilen paketler test ve eğitim verisi olarak YSA’ya tekrar verilerek ağ eğitilmiş ve test edilmiştir. Elde edilen sınıflandırma başarısının ortalamasının alınabilmesi için sonuçlar bellekte tutularak verinin geri kalan kısmı da kullanmak üzere yineleme tüm veri setinin üzerinden geçecek şekilde gerçekleştirilmiş ve her yinelemede kullanılan veri sayısı ve oranı değişmemiş ancak verinin kendisi değişmiştir. Bu sayede tüm veri dengeli bir şekilde hem eğitim hem de test verisi olarak kullanılmıştır.

Çalışmada kullanılan özellik çıkarım yöntemleri ile her kombinasyon için YSA çalıştırıldığında elde edilen sonuçlar Tablo 4.3 ve 4.4’de gösterilmiştir.

Tablo 4.3: Özellik seçimi için tahmini Mahalanobis mesafeleri toplamı
kullanıldığında YSA'nın başarımları sonuçları

maha-s Özellik Çıkarımı Yöntemi												
Öznitelikler	Kullanılan Öznitelikler											
(1)Koltuk Sayısı	X	X	X	X	X	X	X	X	X	X	X	X
(2)Tonaj		X	X	X	X	X	X	X	X	X	X	X
(3)Uçuş Amacı	X	X	X	X	X	X	X	X	X	X	X	X
(4)Basınç										X	X	
(5)Bulut Kapahlığı						X	X	X	X	X	X	X
(6)Bulut Yüksekliği					X	X	X	X	X	X	X	X
(7)Görünürlük							X	X	X	X	X	X
(8)Nem									X	X	X	
(9)QNH-Basınç												X
(10)Rüzgâr Yönü								X	X	X	X	
(11)Rüzgâr Hızı-Knot			X	X	X	X	X	X	X	X	X	X
(12)Sıcaklık				X	X	X	X	X	X	X	X	X
Ortalama Başarım (%)	62.32	78.43	86.41	91.89	92.04	91.18	89.46	92.94	93.69	80.81	80.46	


Tablo 4.4: Özellik seçimi için Öklid mesafelerinin karelerinin toplamı
kullanıldığında YSA'nın başarımları sonuçları

eucl-s Özellik Çıkarımı Yöntemi												
Öznitelikler	Kullanılan Öznitelikler											
(1)Koltuk Sayısı						X	X	X	X	X	X	
(2)Tonaj									X	X	X	
(3)Uçuş Amacı					X	X	X	X	X	X	X	
(4)Basınç										X	X	
(5)Bulut Kapahlığı		X	X	X	X	X	X	X	X	X	X	

(6)Bulut Yüksekliği	X	X	X	X	X	X	X	X	X	X	X
(7)Görünürlük							X	X	X	X	X
(8)Nem				X	X	X	X	X	X	X	X
(9)QNH-Basınç											X
(10)Rüzgâr Yönü	X	X	X	X	X	X	X	X	X	X	X
(11)Rüzgâr Hızı-Knot								X	X	X	X
(12)Sıcaklık			X	X	X	X	X	X	X	X	X
Ortalama Başarım (%)	34.62	51.65	93.02	95.49	95.57	92.64	90.28	92.90	93.20	82.63	80.57

Özellik seçimi için tahmini Mahalanobis mesafeleri toplamı kullanarak sıralandığında ilk 10 özellik ile YSA'nın başarım oranı yaklaşık % 93, Öklid mesafelerinin karelerinin toplamı kullanarak sıralandığında ilk 6 özellik ile YSA'nın başarım oranı yaklaşık % 96 olarak hesaplanmıştır. Elde edilen sonuçlar doğrultusunda özellik seçiminin başarım oranlarına etkisi belirlenmiş, tahmini Mahalanobis mesafeleri toplamı kullanarak özellikler seçildiğinde yaklaşık % 16, Öklid mesafelerinin karelerinin toplamı kullanarak özellikler seçildiğinde ise yaklaşık % 18 başarım oranlarında iyileştirme sağlanmıştır.

Özellik seçimi yöntemlerinden en başarılı sonucu veren tahmini Mahalanobis mesafeleri toplamı için ilk 10, Öklid mesafelerinin karelerinin toplamı için ise ilk 6 özellik ve kayan pencere yöntemi kullanılarak üç gizli katmanlı üç ayrı modelde Şekil 4.2'de gösterildiği gibi Matlab'ta modellenen YSA çalıştırılmıştır. Elde edilen başarım oranlarının detayları sırası ile Tablo 4.5 ve Tablo 4.6'da sunulmuştur. Kayan pencere yöntemi ile yarı yarıya eğitim ve test verisinin kullanılma usulü tez boyunca yapılan uygulamaların hepsinde kullanılmıştır.



Şekil 4.2: Uçuş gecikmeleri için tasarlanan YSA'nın Matlab'ta çalıştırılması

Tablo 4.5: : YSA'nın öğrenmesi için kullanılan veri dağılımları, maha-s kullanılarak seçilen özellikler ve başarımları

		1.Model	2.Model	3.Model	
Veri dağılımı	Her Pencere İçin Kullanılan Toplam Eğitim Verisi Sayısı	5,910	5,910	5,910	
	Eğitim (Penceredeki dağılım)	Zamanında	2,455	2,455	2,455
		Geciken	2,455	2,455	2,455
	Test (Penceredeki dağılım)	Zamanında	500	500	500
		Geciken	500	500	500
YSA	Katmanlardaki nöron sayısı	15-10-10-1	20-10-10-1	25-10-10-1	
	Pencere sayısı	73	73	73	
	Kullanılan özellikler (İlgi sırasına göre 10 adet)	Uçuş amacı – Koltuk Sayısı – Tonaj – Rüzgâr hızı – Sıcaklık – Bulut yüksekliği – Bulut kapalılığı – Görünürlük – Rüzgâr yönü – Nem			
En yüksek tanıma yüzdesi (%)		99.60	99.10	98.50	
En düşük tanıma yüzdesi (%)		67.40	56.40	67.60	
Ortalama tanıma yüzdesi (%)		93.69	93.16	92.53	

Tablo 4.6: YSA'nın öğrenmesi için kullanılan veri dağılımları, eucl-s kullanılarak seçilen özellikler ve başarımları

		1.Model	2.Model	3.Model	
Veri dağılımı	Her Pencere İçin Kullanılan Toplam Eğitim Verisi Sayısı		5,910	5,910	5,910
	Eğitim (Penceredeki dağılım)	Zamanında	2,455	2,455	2,455
		Geciken	2,455	2,455	2,455
	Test (Penceredeki dağılım)	Zamanında	500	500	500
		Geciken	500	500	500
	YSA	Katmanlardaki nöron sayısı		15-10-10-1	20-10-10-1
Pencere sayısı		73	73	73	
Kullanılan özellikler (İlgi sırasına göre 6 adet)		Bulut yüksekliği – Rüzgâr yönü – Bulut kapallığı – Sıcaklık – Nem – Uçuş Amacı			
En yüksek tanıma yüzdesi (%)		99.30	99.10	98.90	
En düşük tanıma yüzdesi (%)		63.90	62.70	64.80	
Ortalama tanıma yüzdesi (%)		95.57	94.77	94.55	

Detayları verilen sonuçlardan da anlaşılacağı gibi gizli katmanda bulunan nöron sayısının fazla olmasının (ilk katmanda olmak üzere 15, 20 ve 25 nöron) başarı oranını arttırmada tek başına yeterli bir parametre olmadığı görülmüştür.

4.1.3.1 Kategorik Özniteliklerin Sahte Özniteliklere Dönüşülmesi İle YSA'nın Çalıştırılması

Veri setinde bulunan “Uçuş Amacı” ve “Rüzgâr Yönü” öznitelikleri kategorik veri olup önceki bölümlerde bu öznitelikler ham verideki mevcut alan kodları ile kullanılmıştır. Bu bölümde uçuş amacı ve rüzgâr yönü öznitelikleri alan değerlerinin her biri için tanımlanan sahte öznitelikler ile YSA eğitilmiştir. Örneğin Uçuş Amacı “Yolcu” (Kod 110) olan değerler için yaratılan sahte öznitelikte bu amaca sahip uçuşlar 1 diğer uçuşlar 0 değeri ile temsil edilmiştir. Bu şekilde uçuş amacı özniteliği için 18 sahte öznitelik, rüzgâr yönü için de 9 sahte öznitelik tanımlanmıştır. Tablo 4.7’de gösterildiği gibi maha-s ve eucl-s özellik seçimi algoritmalarının çalıştırılması sonucunda elde edilen ilgi sıraları elde edilmiştir.

Tablo 4.7: Kategorik özniteliklerin sahte özniteliklere dönüşülmesi ile elde edilen özellik sıraları

Özelliklerin İlgi Sırası	maha-s	eucl-s
1	Uçuş_Amacı_220	Uçuş_Amacı_110
2	Uçuş_Amacı_120	Bulut_Yüksekliği
3	Uçuş_Amacı_415	Rüzgâr_Yönü_E_2
4	Uçuş_Amacı_250	Rüzgâr_Yönü_NE_9
5	Uçuş_Amacı_230	Rüzgâr_Yönü_N_8
6	Uçuş_Amacı_110	Uçuş_Amacı_250
7	Koltuk_Sayısı	Rüzgâr_Yönü_SW_5
8	Uçuş_Amacı_240	Bulut_Kapalılığı
9	Tonaj	Rüzgâr_Yönü_NNW_7
10	Uçuş_Amacı_223	Uçuş_Amacı_415
11	Uçuş_Amacı_214	Sıcaklık
12	Uçuş_Amacı_440	Rüzgâr_Yönü_S_4
13	Uçuş_Amacı_210	Uçuş_Amacı_240
14	Rüzgâr_Yönü_S_4	Nem
15	Rüzgâr_hızı_knot	Rüzgâr_Yönü_SE_3
16	Sıcaklık	Koltuk_Sayısı
17	Rüzgâr_Yönü_N_8	Rüzgâr_Yönü_W_6
18	Bulut_Yüksekliği	Görüş_mesafesi

19	Rüzgâr_Yönü_NE_9	Uçuş_Amacı_230
20	Bulut_Kapalılığı	Rüzgâr_hızı_knot
21	Görüş_mesafesi	Tonaj
22	Rüzgâr_Yönü_SE_3	Uçuş_Amacı_210
23	Rüzgâr_Yönü_NNW_7	Uçuş_Amacı_214
24	Nem	Uçuş_Amacı_220
25	Basınç	Uçuş_Amacı_120
26	Qnh_basınç	Uçuş_Amacı_471
27	Rüzgâr_Yönü_E_2	Rüzgâr_Yönü_C_1
28	Rüzgâr_Yönü_SW_5	Uçuş_Amacı_440
29	Rüzgâr_Yönü_W_6	Uçuş_Amacı_223
30	Uçuş_Amacı_212	Uçuş_Amacı_212
31	Uçuş_Amacı_215	Basınç
32	Uçuş_Amacı_471	Qnh_basınç
33	Rüzgâr_Yönü_C_1	Uçuş_Amacı_215
34	Uçuş_Amacı_213	Uçuş_Amacı_213
35	Uçuş_Amacı_260	Uçuş_Amacı_260
36	Uçuş_Amacı_270	Uçuş_Amacı_270
37	Uçuş_Amacı_470	Uçuş_Amacı_470

Tablo 4.7’de listelenen sonuçlara göre, maha-s özellik seçimi algoritması kullanıldığında uçuş amacı öznitelikleri en etkin öznitelikler çıkarken, eucl-s algoritması kullandığında ise ağırlıklı olarak meteorolojik özniteliklerin en ağırlıklı çıktığı görülmektedir. Seçilen öznitelik algoritması ile belirlenen sahte öznitelikler kullanılarak eğitilen YSA’nın başarımları Tablo 4.8’de listelenmiştir.

Tablo 4.8: Kategorik özniteliklerin sahte özniteliklere dönüşülmesi ile YSA’nın çalıştırılması sonucunda seçilen özellikler ve başarımları

Öznitelik Sayısı	maha-s ile Başarımları Oranı (%)	eucl-s ile Başarımları Oranı (%)
2	69.17	57.09
3	81.67	57.23
4	86.89	54.03
5	91.94	57.43
6	94.95	57.44
7	77.28	57.08
8	73.67	81.24
9	89.84	82.12
10	87.10	81.84
11	88.28	77.13

12	87.34	81.68
13	89.03	74.06
14	84.54	73.64
15	77.83	73.14
16	74.98	69.84
17	68.03	63.45
18	74.77	56.99
19	69.34	53.17
20	82.59	51.98
21	65.47	54.25
22	69.16	56.23
23	66.99	54.55
24	61.83	53.94
25	75.79	53.85
26	76.37	55.39
27	74.49	54.07
28	69.98	56.71
29	74.97	55.72
30	74.23	58.19
31	75.12	72.53
32	76.86	71.00
33	76.28	71.43
34	72.36	69.54
35	71.55	71.02
36	72.35	73.64
37	72.49	74.57

Tablo 4.8’de gösterildiği üzere maha-s özellik seçme algoritmasına göre maksimumda % 94.95 ortalama da % 77.10, eucl-s özellik seçme algoritmasına göre maksimumda % 82.12 ortalama da % 64.37 başarımlar elde edilmiştir. Alan kodları kullanmak yerine kategorik verilerin sahte özniteliklerle ifade edilmesi YSA eğitiminde ciddi bir farklılık yaratmadığı gözlenmiştir.

4.1.4 Zaman Boyutunda Uygulama ve İnceleme

Uçuş verisinde zaman boyutu da olduğu için tasarlanan model mevsimsel olarak da incelenmiştir. Veri seti Sonbahar, Kış, İlkbahar ve Yaz olarak 4’e parçalanmıştır. Sonbahar mevsiminde eğitim ve test verisi olarak Eylül, Ekim ve Kasım ayları, Kış mevsimi için Aralık, Ocak ve Şubat ayları, İlkbahar mevsimi için Mart, Nisan ve Mayıs ayları, Yaz mevsimi için ise Haziran, Temmuz ve Ağustos aylarındaki veriler kullanılmış ve YSA’nın uçuş gecikme tahmin başarımlarını her mevsim için sırası ile Tablo 4.9, 4.10, 4.11 ve 4.12’de sunulmuştur. Uçuş gecikme tahmini için geliştirilen modelin, hava şartlarının uçuş için olumsuz olduğu düşünülen kış ve

sonbahar mevsimlerindeki başarımların yaz ve ilkbahar mevsimlerine göre ortalama % 1 daha düşük olduğu görülmüştür. Özellik seçimi olarak Öklid mesafelerinin karelerinin toplamı uygulandığında tüm veri seti kullanıldığında en ağırlıklı 6 öznitelik ile ortalama % 96 tahmin başarımları elde edilirken, mevsimsel değerlendirme de başarımların % 70'in altına düştüğü görülmüştür. Aynı şekilde tahmini Mahalanobis mesafeleri toplamı özellik seçimi uygulandığında tüm veri seti kullanıldığında en ağırlıklı 10 öznitelik ile ortalama % 93 tahmin başarımları elde edilirken, mevsimsel değerlendirme de başarımların ortalama % 75 olduğu gözlemlenmiştir.

Veri sezonsal olarak incelendiğinde verilen özniteliklerle öğrenilen modellerin başarımları verilerin bütüncül olarak kabul edildiğinde öğrenilen modelin başarımları ile karşılaştırıldığında % 90'ın üzerinden % 70'lere kadar olan bir düşüş gözlemlenmiştir. Bu sonuca neden olabilecek etkenler aşağıdaki şekilde yorumlanmıştır:

- 1- Dönemsel veri miktarının sınırlı sayıda olması.
- 2- Özniteliklerin değer aralıklarındaki değişimin sınırlı olması.

Tablo 4.9: Uçuş gecikme tahmini için tasarlanan YSA'nın özellik seçimi kullanılarak elde edilen sonbahar mevsimi içindeki başarımları

Kullanılan Özellik Sayısı	1.Model (15-10-10)	2.Model (20-10-10)	3.Model (25-10-10)
6 *	68.15	67.80	68.49
10 **	73.97	72.60	72.26
12	72.77	72.20	70.88

* Tablo 4.6'deki parametrelere göre çalışır.

** Tablo 4.5'deki parametrelere göre çalışır.

Tablo 4.10: Uçuş gecikme tahmini için tasarlanan YSA'nın özellik seçimi kullanılarak elde edilen kış mevsimi içindeki başarımlar oranları

Kullanılan Özellik Sayısı	1.Model (15-10-10)	2.Model (20-10-10)	3.Model (25-10-10)
6 *	64.91	64.91	64.91
10 **	70.16	72.58	71.77
12	70.16	69.35	71.46

* Tablo 4.6'daki parametrelere göre çalışır.

** Tablo 4.5'deki parametrelere göre çalışır.

Tablo 4.11: Uçuş gecikme tahmini için tasarlanan YSA'nın özellik seçimi kullanılarak elde edilen ilkbahar mevsimi içindeki başarımlar oranları

Kullanılan Özellik Sayısı	1.Model (15-10-10)	2.Model (20-10-10)	3.Model (25-10-10)
6 *	64.32	64.32	64.02
10 **	76.21	76.52	75.60
12	73.92	73.98	74.12

* Tablo 4.6'daki parametrelere göre çalışır.

** Tablo 4.5'deki parametrelere göre çalışır.

Tablo 4.12: Uçuş gecikme tahmini için tasarlanan YSA'nın özellik seçimi kullanılarak elde edilen yaz ayı içindeki başarı oranları

Kullanılan Özellik Sayısı	1.Model (15-10-10)	2.Model (20-10-10)	3.Model (25-10-10)
6 *	62.58	61.93	62.25
10 **	72.90	72.25	71.29
12	72.97	72.26	72.09

* Tablo 4.6'daki parametrelere göre çalışır.

** Tablo 4.5'deki parametrelere göre çalışır.

Uçuş gecikme tahmini için tasarlanan YSA'nın mevsimsel olarak çalıştırıldığı parametre değerleri Tablo 4.13'de verilmiştir. Kayan pencere yöntemi burada da kullanılmış ve veri boyutuna göre değerleri farklılık göstermiştir.

Tablo 4.13: YSA'nın mevsimsel zaman boyutunda parametre değerleri

UÇUŞ TAHMİN MEVSİMSEL YSA MODELİ SONUÇLARI		Sonbahar	Kış	İlkbahar	Yaz
Test ve Eğitim İçin Kullanılan Toplam Verisi Sayısı		10,030	9,176	9,942	10,744
Her Pencere İçin Kullanılan Toplam Eğitim Verisi Sayısı		1168	998	1318	1248
Eğitim (Penceredeki dağılım)	Zamanında	584	499	659	624
	Geciken	584	499	659	624
Test (Penceredeki dağılım)	Zamanında	146	124	164	155
	Geciken	146	124	164	155
YSA	Pencere sayısı	63	68	55	64

4.1.5 Dakika Bazlı Uygulama ve İnceleme

Uçuş gecikme tahmini için tasarlanan YSA'nın dakika bazlı sınıflandırma başarısı da incelenmiştir. Geciken uçuşların dakika bazlı dağılımları Tablo 4.14'de listelenmiştir. Tablo 4.14'e göre 30 dakika ve altı olan gecikmelerin toplam geciken uçuşlara oranının % 85.23 olduğu görülmektedir. Aralık bazlı dağılım ise Tablo 4.15'de gösterilmiştir. Tabloya göre özellikle 10 ve 30 dakika arası gecikme sayısının baskın olduğu gözükmemektedir. Tablo 4.14 ve 4.15'de verilen bilgiler tamamen istatistiki bilgi amacı ile verilmiştir. Bu verilerle herhangi bir deneysel çalışma yapılmamış ve sonuç bazında gruplama yapılmıştır.

Tablo 4.14: Esenboğa Havalimanından 2014 yılı için alınan uçuş bilgilerinin dakika bazlı gecikme dağılımı

Dakika	Veri Sayısı
1 dakika ve altı (≤ 1 dk.)	824
5 dakika ve altı (≤ 5 dk.)	6.275
10 dakika ve altı (≤ 10 dk.)	15.194
30 dakika ve altı (≤ 30 dk.)	31.482
60 dakika ve altı (≤ 60 dk.)	34.932
120 dakika ve altı (≤ 120 dk.)	36.216
180 dakika ve altı (≤ 180 dk.)	36.593
360 dakika ve altı (≤ 360 dk.)	36.847
720 dakika ve altı (≤ 720 dk.)	36.883
1440 dakika ve altı (≤ 1440 dk.)	36.937

Tablo 4.15: Esenboğa Havalimanından 2014 yılı için alınan uçuş bilgilerinin dakika aralık bazlı gecikme dağılımı

Dakika	Veri Sayısı
1 dakika ve altı (≤ 1 dk.)	824
1 ve 5 dakika arası ($1 \text{ dk.} < x \leq 5 \text{ dk.}$)	5.451
5 ve 10 dakika arası ($5 \text{ dk.} < x \leq 10 \text{ dk.}$)	8.919
10 ve 30 dakika arası ($10 \text{ dk.} < x \leq 30 \text{ dk.}$)	16.288
30 ve 60 dakika arası ($30 \text{ dk.} < x \leq 60 \text{ dk.}$)	3.450
60 ve 120 dakika arası ($60 \text{ dk.} < x \leq 120 \text{ dk.}$)	1.284
120 ve 180 dakika arası ($120 \text{ dk.} < x \leq 180 \text{ dk.}$)	377
180 ve 360 dakika arası ($180 \text{ dk.} < x \leq 360 \text{ dk.}$)	254
360 ve 720 dakika arası ($360 \text{ dk.} < x \leq 720 \text{ dk.}$)	36
720 ve 1440 dakika arası ($720 \text{ dk.} < x \leq 1440 \text{ dk.}$)	54

Bölüm 4.1.3'te anlatılan Tablo 4.5'te detayları verilen YSA'nın sonuçlarının gecikme süreleri gruplandırıldığında elde edilen dağılımlar Tablo 4.16 ve 4.17'de verilmiştir.

Tablo 4.16: Bölüm 4.1.3'te anlatılan Tablo 4.5'te detayları verilen YSA'nın sonuçlarının dakika bazlı doğru sınıflandırma oranları

Gecikme Süreleri(dk.)	≤ 1	≤ 5	≤ 10	≤ 30	≤ 60	≤ 120	≤ 180	≤ 360	≤ 720	≤ 1440
Pencerelerdeki Ortalama Doğru Sınıflandırma Oranı (%)	96.34	94.58	95.06	92.43	96.86	89.84	92.52	83.21	98.63	94.68

Tablo 4.17: Bölüm 4.1.3'te anlatılan Tablo 4.5'te detayları verilen YSA'nın sonuçlarının dakika aralık bazlı doğru sınıflandırma oranları

Gecikme Süreleri(dk.) (Aralıklı)	≤ 1	$1 < x \leq 5$	$5 < x \leq 10$	$10 < x \leq 30$	$30 < x \leq 60$	$60 < x \leq 120$	$120 < x \leq 180$	$180 < x \leq 360$	$360 < x \leq 720$	$720 < x \leq 1440$
Pencerelerdeki Ortalama Doğru Sınıflandırma Oranı (%)	91.85	87.96	90.02	86.39	92.92	81.18	83.72	74.61	100	51.02

Verideki uçuşların gecikme sürelerinin dengeli dağılımda olmamasına rağmen YSA modelinin değişik gecikme süreleri için de benzer başarımları gösterdiği gözlemlenmiştir.

4.1.6 Öznitelik Bazlı Uygulama ve İnceleme

Bölüm 3.1.1'de anlatıldığı gibi havalimanından alınan özniteliklerden 9 tanesi hava durumu, 3 tanesi ise uçak ve uçuş bilgilerini temsil etmektedir. Bölüm 4.1.1'de anlatıldığı üzere veri setine özellik seçimi uygulanmış, aynı zamanda Bölüm 4.1.4'de olduğu gibi zaman boyutunda mevsimsel olarak da tasarlanan YSA'nın başarısı ölçülmüştür. Bunun yanı sıra YSA'ya sadece hava durumu ve uçak/uçuş bilgileri öznitelikleri verilerek başarımları ölçülmüştür. Sonuçlara göre sadece hava durumu öznitelikleri verilerek elde edilen başarımları ortalama % 71.14, sadece uçak/uçuş bilgileri verilerek elde edilen başarımları ise ortalama % 82.38 olarak bulunmuştur.

Elde edilen bu sonuçlar uçuş gecikme tahmini için tasarlanan YSA'da veri seti olarak sadece uçak/uçuş bilgilerinin kullanmanın sadece meteorolojik verilerin kullanılmasına göre daha başarılı sonuç verdiğini göstermektedir. Öznitelik seçimi yaklaşımlarının kullanılması ile belirlenen özelliklerin sıralanması ve seçimi sonucunda başarımlarının % 96'lara çıktığı gözlemlenmiştir. Bu nedenle gecikme belirlemeleri için ilgili özellik türlerinin birlikte kullanılması önerilmektedir.

BEŞİNCİ BÖLÜM

SONUÇLAR

5.1 Sonuç

Uçakların planlanan kalkış zamanındaki gecikmelerin tahmin edilmesi ve uyarı sistemlerinin geliştirilmesi, gecikmelerden kaynaklanan maliyetlerin en aza indirilmesi ve yolcuların memnuniyetlerin artırılması için önem arz etmektedir. Bu çalışmada havalimanındaki algılayıcılardan toparlanan hava durumu verilerinin uçak/uçuş bilgileri ile zenginleştirilmesi sonucu elde edilen öznitelikler kullanılarak denetimli bir öğrenme modeli olan geri beslemeli bir Yapay Sinir Ağları ile gecikme tahmin modeli tasarlanmış ve gerçekleştirilmiştir.

Veri seti Ankara Uluslararası Esenboğa Havalimanından 2014 yılı içerisinde 1 yıllık olarak alınmıştır. Gerekli veri temizleme işleminden sonra kalan 39.892 uçuş için planlanan kalkış zamanındaki 9 çeşit hava ölçüm değeri ve 3 adet uçak/uçuş ile ilgili bilgidен oluşan öznitelik kümesini içermektedir. Hava öznitelikleri basınç, bulut kapallığı, bulut yüksekliği, görünürlük, nem, QNH-basınç, rüzgâr yönü, rüzgâr hızı (knot) ve sıcaklık olarak, uçak/uçuş bilgileri olarak ta uçaktaki koltuk sayısı, uçak ağırlığı (Tonaj), uçuş amacı alınmıştır. Hava öznitelikleri havalimanının içerisindeki meteoroloji ölçüm kulesinden her saati 50 geçe alınmıştır. Uçuşların planlanan ve gerçekte kalkış saatleri çıkarılarak fark alanı elde edilmiştir. Veri setindeki uçuşlardan 36.937 adeti geciken uçuş, 2.955 adeti de zamanında gerçekleşen uçuştan oluşmaktadır.

Özniteliklerin ilgi sırası iç-dış mesafe (in-in), tahmini Mahalanobis mesafeleri toplamı (maha-s) ve Öklid mesafelerinin karelerinin toplamı (eucl-s) yöntemleri kullanılarak belirlenmiştir. Özellik çıkarımı yöntemlerinden iç-dış mesafe özellik seçimi (in-in) ile tahmini Mahalanobis mesafeleri toplamı özellik seçiminin aynı davranışı gösterdiği belirlenmiştir. Öznitelikler belirleyici özelliklerine göre iç-dış mesafe özellik seçimi (in-in) ve tahmini Mahalanobis mesafeleri toplamı özellik

seçimi kullanılarak sıralandığında uçak/uçuş bilgilerini içeren sırası ile uçuş amacı, uçaktaki koltuk sayısı ve tonaj en belirleyici öznitelikler olarak listelenmiştir. Buna karşın Öklid mesafelerinin karelerinin toplamı (eucl-s) yöntemi kullanıldığında meteorolojik verilerin daha belirleyici öznitelikler olduğu görülmüştür. Her üç yöntemde de basınç özniteliklerinin ilgi sırasının en az olduğu tespit edilmiştir.

Denetimli öğrenme sonucunda oluşturulan üç katmanlı, her katmanında sırası ile 15-10-10 adet nöron sayısı olan, Levenberg-Marquardt geri yayılım eğitim algoritması, performans fonksiyonu olarak ortalama hata kareleri toplamı, hiperbolik-tanjant aktivasyon fonksiyonu kullanan Yapay Sinir Ağı modeli ile uçuşlardaki kalkış gecikmeleri ortalamada bütün veri kullanıldığında yaklaşık % 93, zamanında ve gecikmeli uçuşlar dengeli bir şekilde parçalanarak kayan pencere yöntemi kullanıldığında farklı özellik seçimi yöntemleri ile yaklaşık % 92 ile % 96 arasında bir tahmin başarısı elde edilmiştir.

Ayrıca mevsimsel olarak başarı ölçümü de yapılmıştır. Buna göre mevsimsel değerlendirmede ise sonbahar, kış, ilkbahar ve yaz için sırası ile uçuş gecikme tahmini başarısı ortalama % 71, % 70, %75 ve % 73 olarak elde edilmiştir. Başarım oranının düşmesine neden olan etkenlerin dönemsel veri miktarının sınırlı sayıda olması ve özniteliklerin değer aralıklarındaki değişimin sınırlı olması şeklinde yorumlanmıştır.

İleride yapılacak çalışmalar da aynı günkü uçuş sayısı, mevsim bilgisi, gecikmelerin mesai saati ile olan değişimi gibi yeni öznitelikler veri setine eklenerek başarım oranları yeniden ölçülebilir. Bir uçuştan belirli bir süre önce olan gecikmenin o uçuşu etkileyip etkilemediği sorusuna cevap vermek için farklı yöntemler geliştirilebilir.

Aynı zamanda gün içinde birbirlerini etkileyen uçuşların tespit edilmesi, veri seti içerisinde ilk gecikmenin ne zaman olduğu gibi çalışmalar yapılabilir. YSA'nın öznitelik sayısının artması gibi nedenlerle başka yöntemlerin kullanılması da göz önüne alınabilir. Ayrıca www.flightradar24.com gibi canlı uçuş bilgilerinin alınabildiği açık veri setlerinin kullanılması ile veri setinin zenginleştirilerek tasarlanan modellerin başarısı farklı lokasyonlar için ölçülebilir.

KAYNAKÇA

- B. Laskey, K., Xu, N., & Chen, C.-H. (2012). Propagation of Delays in the National Airspace System. *Center for Air Transportation Research and SEOR Department, George Mason University.*
- A. ZeinEldin, R. (2014). A Neural Network Model For Flights Delay: Classification And Prediction. *Global Journal Of Engineering Science And Researches, 1(6), 13-22.*
- Ayas, S. (2014). Mikroskopik İmgelerde Tüberküloz Bakterisinin Rastgele Ormanlar Yöntemiyle Sınıflandırılması. *Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği, Yüksek Lisans Tezi.*
- Bandyopadhyay, R., & Guerrero, R. (2012). Predicting airline delays.
- Bir Bakışta Uçuş Gecikmeleri : ABD Ulaştırma Bürosu.* (2016). United States Department of Transportation Web Sitesi: http://www.transtats.bts.gov/HomeDrillChart.asp?URL_SelectYear=2015&URL_SelectMonth=11&URL_Time=1&URL_Selection=1 adresinden alındı
- Bishop, C. (1995). *Neural Networks for Pattern Recognition.* New York: Oxford University Press .
- Brett, N. (2008). Airline Departure Delay Prediction. *Stanford University, Machine Learning Lesson Final Project.*
- Cheng, J. (2014). Risk Management Using Big Real Time Data. *University Of Stavanger, Master Thesis.*
- Dey, T., Phillips, D., & Steele, P. (2009). Minimizing Flight Delay. *Data Expo.* Washington.
- Duda, R., Hart, P., & Stork, D. (2001). *Pattern Classification (2.Baskı b.).* New York: John Wiley and Sons.

- EUR-Lex*. (2015). Avrupa Birliđi Yasalarına Eriřim Web Sitesi: <http://eur-lex.europa.eu/> adresinden alındı
- Fausett, L. (1994). *Fundamentals of Neural Networks*. New York: Prentice Hall.
- Ferrer, J.-C., Oliveira, P., & Parasuraman, A. (2012). The behavioral consequences of repeated flight delays. *Journal of Air Transport Management*, 20, s. 35-38.
- Fleurquin, P., Ramasco, J., & M. Eguiluz, V. (2013). Data-driven modeling of systemic delay propagation under severe meteorological conditions. *Tenth USA/Europe Air Traffic Management Research and Development Seminar*, (s. 1-9). Chicago.
- Guyon, I., & Elisseeff, A. (2003). An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research*(3), 1157-1182.
- Güneř, T., & Polat, E. (2009). Yüz ifade analizinde öznitelik seçimi ve çoklu svm sınıflandırıcılarına etkisi. *Gazi Üniv. Müh. Mim. Fak. Der.*, 24(1), 7-14.
- Hansen, B., & Riordan, D. (2000). *Weather Prediction Using Case-Based Reasoning and Fuzzy Set Theory*. Doctoral dissertation, DalTech.
- İngiltere Sivil Havacılık Sitesi*. (2016). İngiltere Sivil Havacılık Sitesi: <https://www.caa.co.uk/> adresinden alındı
- Karsoliya, S. (2012). Approximating Number of Hidden layer neurons in Multiple Hidden Layer BPNN Architecture. *International Journal of Engineering Trends and Technology*, 3(6).
- Kaynak, O., & Efe, Ö. (2000). *Yapay Sinir Ağları ve Uygulamaları*. İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Klein, A., Craun, C., & Lee, R. (2010). Airport delay prediction using weather-impacted traffic index (WITI) model. *29th Digital Avionics Systems Conference (DASC)*. DOI: 10.1109/DASC.2010.5655493, s. 1-13. IEEE/AIAA.
- Liu, H., & Motoda, H. (2007). *Computational Methods of Feature Selection*. Chapman and Hall/CRC Press.

- Martinez, V. (2012). Flight Delay Prediction. *Swiss Federal Institute of Technology Zurich, Department of Computer Science, Master's Thesis.*
- MathWorks.* (2015). <http://www.mathworks.com/help/nnet/ref/trainlm.html> adresinden alındı
- Mukherjee, A., Grabbe, S., & Sridhar, B. (2014). Predicting Ground Delay Program At An Airport Based On Meteorological Conditions. I. a. 14th AIAA Aviation Technology (Dü.). içinde Atlanta. doi:10.2514/6.2014-2713
- Narin, A., İşler, Y., & Özer, M. (2014). Konjestif Kalp Yetmezliği Teşhisinde Kullanılan Çapraz Doğrulama Yöntemlerinin Sınıflandırıcı Performanslarının Belirlenmesine Olan Etkilerinin Karşılaştırılması. *Dokuz Eylül Üniversitesi, Mühendislik Fakültesi, Mühendislik Bilimleri Dergisi*, 16(48), 1-8.
- Onan, A., & Korukoğlu, S. (2015). Metin Sınıflandırmada Öznitelik Seçim Yöntemlerinin Değerlendirilmesi. *IEEE 23. Sinyal İşleme ve İletişim Uygulamaları*, (s. 2-5). Malatya.
- Öztemel, E. (2003). *Yapay Sinir Ağları* (Birinci Baskı b.). İstanbul: Papatya Yayıncılık.
- PRTOOL,2015.* (2015). PRTOOL: <http://www.37steps.com> adresinden alındı
- Robinson, P. J. (1989). The influence of weather on flight operations at the Atlanta Hartsfield International Airport. *Weather and forecasting*, 4(4), 461-468.
- Sridhar, B., Wang, Y., Klein, A., & Jehlen, R. (2009). Modeling Flight Delays and Cancellations at the National, Regional and Airport Levels in the United States. *Eighth USA/Europe Air Traffic Management Research and Development Seminar(ATM2009)*. California.
- Topal, T. (2010). Kardiyak Doppler İşaretleri Analiz Ve Sınıflandırma Sistemi: Kardias. *Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.*
- Ünsalan, C., & Erçil, A. (1998). Öznitelik Seçme Yöntemlerinin Karşılaştırılması ve Başarı Kriteri. *Proceedings of IEEE SIU Kızılcahamam*, 60-65.
- Valdez, J. (2000). *NWS reinventing goals for 2000. National Weather Service, National Oceanic and Atmospheric Administration, United States Department*

of Commerce, Washington, DC . <http://govinfo.library.unt.edu/npr/library/announc/npr5.htm> adresinden alındı

Vranas, P., Bertsimas, D., & Odoni, A. (1994). The multi-airport ground-holding problem in air traffic control. *Operations Research*, 42(2), 249-261.

Xu, N., Sherry, L., & Laskey, K. B. (2008). Multi-Factor Model For Predicting Delays At U.S. Airports. *Transportation Research Record Journal Of The Transportation Research Board*, (s. 62-71). doi:<http://dx.doi.org/10.3141/2052-08>

Zonglei, L., Jiandong, W., & Guansheng, Z. (2008). A New Method to Alarm Large Scale of Flights Delay Based on Machine Learning. *International Symposium on Knowledge Acquisition and Modeling*, (s. 589-592). China.

Ek A

DENKLEMLER

DENKLEM 3.1 İÇ MESAFE FONKSİYONU	22
DENKLEM 3.2 DIŞ MESAFE FONKSİYONU	22
DENKLEM 3.3 MAHALANOBİS DISTANCES FONKSİYONU	23
DENKLEM 3.4 MAHALANOBİS BENZERLİK ÖLÇÜTÜ	23
DENKLEM 3.5 ÖKLİD MESAFE ÖLÇÜTÜ	24
DENKLEM 3.6 PİSAGOR FONKSİYONU	24
DENKLEM 3.7 YSA İÇİN NET GİRDİ FONKSİYONU	26
DENKLEM 3.8 YSA ÇALIŞTIRILDIKTAN SONRA ELDE EDİLEN ÇIKTININ MATEMATİKSEL TANIMI	26
DENKLEM 3.9 TANSİG FONKSİYONUNUN MATEMATİKSEL İFADESİ	27
DENKLEM 3.10 LOGSİG FONKSİYONUNUN MATEMATİKSEL İFADESİ	27
DENKLEM 4.1 ORTALAMA KARELER HATASININ MATEMATİKSEL İFADESİ	37
DENKLEM 4.2 ORTALAMA MUTLAK HATANIN MATEMATİKSEL İFADESİ	37

Ek B

TEST VERİLERİNE GÖRE BAŞARIM ORANLARI

Feature Seleccion	Giriş Sayısı	Transfer Fonk.	Nöron Sayısı	Eğitim Fonk.	Performans Fonk.	Başarı %
maha-s	8	tansig	24	trainlm	mse	80
maha-s	8	tansig	22	trainbr	mse	79
maha-s	7	logsig	28	trainlm	mse	78
maha-s	12	tansig	29	trainbr	msereg	78
eucl-s	7	logsig	22	trainlm	mae	77
maha-s	11	logsig	17	trainbr	msereg	77
maha-s	12	logsig	25	trainbr	mae	77
maha-s	12	tansig	18	trainbr	mae	77
maha-s	10	tansig	30	trainlm	msereg	76
maha-s	12	tansig	25	trainlm	mse	76
maha-s	12	tansig	19	trainbr	mae	76
eucl-s	12	tansig	28	trainbr	mae	76
maha-s	12	tansig	30	trainlm	mae	76
maha-s	12	logsig	20	trainbr	mae	76
eucl-s	8	tansig	24	trainlm	msereg	76
maha-s	9	logsig	16	trainbr	mae	76
maha-s	12	tansig	26	trainbr	msereg	76
maha-s	12	logsig	23	trainlm	msereg	76
maha-s	7	logsig	30	trainbr	msereg	76
maha-s	10	tansig	30	trainbr	mae	76

maha-s	11	tansig	25	trainbr	mse	76
maha-s	12	tansig	18	trainlm	msereg	76
maha-s	12	tansig	30	trainlm	msereg	76
maha-s	12	logsig	27	trainbr	msereg	76
maha-s	10	tansig	12	trainbr	mae	76
maha-s	11	logsig	25	trainbr	mse	76
maha-s	3	tansig	8	traincgp	mse	75
eucl-s	6	logsig	24	trainbr	msereg	75
maha-s	7	logsig	25	trainlm	msereg	75
eucl-s	7	logsig	29	trainbr	mae	75
maha-s	7	logsig	29	trainbr	msereg	75
maha-s	11	logsig	27	trainlm	mse	75
maha-s	12	logsig	21	trainlm	msereg	75
maha-s	12	logsig	21	trainbr	msereg	75
maha-s	12	logsig	28	trainbr	msereg	75
maha-s	12	logsig	29	trainlm	msereg	75
maha-s	3	tansig	28	traincgp	mse	75
eucl-s	6	tansig	9	trainbr	mse	75
maha-s	8	tansig	12	trainbr	mse	75
maha-s	9	logsig	27	trainbr	msereg	75
maha-s	12	tansig	24	trainbr	msereg	75
maha-s	12	logsig	16	trainbr	mse	75
maha-s	12	tansig	24	trainbr	mse	75
maha-s	12	tansig	25	trainlm	msereg	75
eucl-s	9	logsig	23	trainlm	mae	75
maha-s	12	tansig	17	trainbr	mse	75
maha-s	12	tansig	21	trainbr	msereg	75

maha-s	12	logsig	26	trainbr	msereg	75
maha-s	12	tansig	25	trainlm	msereg	75
maha-s	9	logsig	28	trainlm	mae	75
maha-s	11	tansig	27	trainbr	msereg	75
maha-s	7	logsig	17	trainbr	mae	75
maha-s	10	tansig	18	trainlm	mae	75
maha-s	10	logsig	27	trainlm	mae	75
maha-s	12	logsig	25	trainbr	mse	75



Ek C

UÇUŞ AMAÇLARI

Uçuş Kodu	Amacın Açık Adı
110	Yolcu
120	Kargo-Genel Kargo
121	Kargo-Canlı Hayvan Nakli
122	Kargo-Bozulabilir Kargo(Çiçek/Sebze)
123	Kargo-Tehlikeli Madde Nakli
124	Kargo-Posta
125	Kargo-Yolcu/Kabinde Taşınan Kargo
210	Yolcu-Turistik Charter
211	Yolcu-Turistik Charter(IT)
212	Yolcu-Ambulans (Ücret Alınan)
213	Yolcu-İşçi Charter
214	Yolcu-Hac Uçuşu
215	Yolcu-özel yolcu(tutuklu,göçmen..vb)
216	Yolcu-Ambulans (Ücret Alınmayan)
220	Kargo-Genel Kargo
221	Kargo-Canlı Hayvan Nakli
222	Kargo-Bozulabilir Kargo(Çiçek/Sebze)
223	Kargo-Tehlikeli Madde Nakli

224	Kargo-Posta
225	Kargo-Yolcu/Kabinde Taşıman Kargo
226	Kargo-Bavul Ticareti
230	Teknik İniş-Kalkış
240	İntikal Uçuşu(Boş Uçuş)
250	İş Uçuşu
260	Divert-Kalktığı Meydana Dönüş
270	Divert-Yedek Meydana İniş
310	Devlet Uçuşu(VIP Statüsünde Olmayan)
320	VIP(Ücretsiz)
321	Resmi Olmayan VIP(Ücret Alınan)
330	Askeri-Ücretli
331	Askeri-T.C.
332	Askeri-ABD
334	Askeri-Teknik
340	Gümrük
410	Orman Gn.Md-Koruma Kontrol
411	Orman Gn.Md-Yangın Söndürme
412	Tapu Kadastro
413	Emniyet Genel Müdürlüğü
414	Zirai Mücadele
415	Özel Uçuş (Ticari Olmayan)
416	Türk Hava Kurumu

420	Hava Taksi (Ticari)
430	Üçüncü Yaş Turizmi
440	Eğitim Uçuşu (Ticari Amaçlı Uçuş Eğitimi)
441	Eğitim Uçuşu (Havayolu Şirketleri)
450	Test,Tecrübe Uçuşu
460	Uçuş Kontrol (Flight Check)
470	İnsani Yardım
471	Sivil Uçakla Asker Sevkiyatı
480	Arama Kurtarma
490	Döviz Atımı
491	Pano Çekimi
492	Fotoğraf-Film Çekimi
493	Paraşüt Atlayışı
494	Maden Arama
495	Akrobasi Uçuşu
496	Motorlu Yelken Kanat Uçuşu
497	Su Uçuşu-Zeplin
498	Balon Uçuşu
499	Sportif Faaliyetler

Ek D

MATLAB'TA ÇALIŞAN EĞİTİM FONKSİYONLARI

Eğitim Fonksiyonu	Fonksiyonun Açılımı
trainbfg	BFGS quasi-Newton backpropagation
trainbr	Bayesian regularization backpropagation
traincgb	Conjugate gradient backpropagation with Powell-Beale restarts
traincgf	Conjugate gradient backpropagation with Fletcher-Reeves updates
traincgp	Conjugate gradient backpropagation with Polak-Ribière updates
traingd	Gradient descent backpropagation
traingda	Gradient descent with adaptive learning rate backpropagation
traingdm	Gradient descent with momentum backpropagation
traingdx	Gradient descent with momentum and adaptive learning rate backpropagation
trainoss	One-step secant backpropagation
trainrp	Resilient backpropagation
trainscg	Scaled conjugate gradient backpropagation
trainb	Batch training with weight and bias learning rules
trainc	Cyclical order weight/bias training
trainr	Random order incremental training with learning functions

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Vahap Burhan DEMİR

Uyruğu : T.C.

Doğum Yeri ve Tarihi: Kayseri – 15.09.1983

Medeni Hali : Evli

Adres : Şeyhşamil Mah. 586.Sok. No:3/12

Etimesgut/ANKARA E-Posta Adresi: vahapburhan@gmail.com

İletişim (Telefon) : 0 505 565 69 18

EĞİTİM

Lise : Elazığ Lisesi (Elazığ) - 1999

Lisans : Fırat Üniversitesi/Bilgisayar Mühendisliği (Elazığ) -2005

Yüksek Lisans : Türk Hava Kurumu Üniversitesi/Elektrik ve Bilgisayar Mühendisliği (Ankara) – Devam Ediyor

TEZ ve PROJELER

UYAP SMS Sistemi-Proje Yöneticisi,

UYAP Avukat,Vatandaş,Kurum Portallar Projesi-Proje Yöneticisi,

UYAP İstinaf Mahkemeleri Projesi-Proje Yöneticisi,

UYAP E-Satış Sistemi Projesi-Proje Yöneticisi

İŞ DENEYİMİ

2006- : Adalet Bakanlığı Bilgi İşlem Dairesi Başkanlığı