

T.C.
HALIÇ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**UÇAK KARA KUTUSUNDAN
ALINAN KAYITLARIN
YAPAY SİNİR AĞLARI İLE
İNCELENMESİ**

YÜKSEK LİSANS TEZİ

Hazırlayan

Yaşar ALTUNTAŞ

Tez Danışmanı

Prof. Dr. Ali OKATAN

**Ağustos 2007
İSTANBUL**

T.C.
HALIÇ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜNE

Bilgisayar Mühendisliği Programı Yüksek Lisans öğrencisi Yaşar Altuntaş tarafından hazırlanan “Uçak Kara Kutusundan Alınan Kayıtların Yapay Sinir Ağları İle İncelenmesi” adlı bu çalışma jürimizce Yüksek Lisans Tezi olarak Kabul Edilmiştir.

Tez Savunma Tarihi : 14/09/2007

(Jüri Üyesinin Ünvanı , Adı , Soyadı ve Kurumu) :

İmzası :

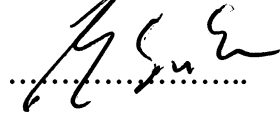
Jüri Üyesi: Prof.Dr.Ali OKATAN
(Danışman)



Jüri Üyesi : Prof.Dr.Bekir KARAOĞLU
(Uygulamalı Matematik ABD)



Jüri Üyesi :Prof.Dr.Sami Ercan
(Endüstri Mühendisliği ABD)



ÖNSÖZ

Uçak kara kutusundan alınan verilerin yapay sinir ağı ile analizinin yapılarak uçak yakıt tüketim tahmininin yapıldığı bir model geliştirilmiştir. Bu çalışma için danışmanlığımı üzerine alarak, çalışma boyunca tecrübeleri veengin bilgisi ile gerekli yol ve yöntemleri gösteren hocamız Prof. Dr. Ali Okatan'a ayrıca teknik desteğini esirgemeyen Türk Hava Yolları A.O.'na teşekkürü bir borç biliyorum.

Bu zamana kadar zor zamanlarımda hep yanımda olan, hayatımın her karesine fedekarlıklarımı nakşeden, sıkıntılarımı paylaşıp teselli veren ve bizi şefkatle yetiştiren aileme karşı hislerime tercüman olacak kelime bulamıyor ve ancak "sizlere de teşekkürler" diyebiliyorum.

Yaşar ALTUNTAŞ

Ağustos 2007

İÇİNDEKİLER

	Sayfa no
ÖNSÖZ	ii
İÇİNDEKİLER	iii
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	viii
KISALTMALAR	ix
ÖZET	x
ABSTRACT	xi
1. GİRİŞ	1
1.1. Tarihçesi.....	1
1.2. Araştırmaya Yaklaşım ve Amacı.....	2
2. LİTERATÜRÜN İNCELENMESİ	4
2.1 Giriş.....	4
2.2 Uçak Verileri Kayıt Sistemi (FDRS).....	4
2.2.1 FDRS Komponentleri.....	7
2.2.2 FDR Parametreleri.....	8
2.2.2.1 Airspeed.....	8
2.2.2.2 Altitude.....	9
2.2.2.3 TAT (Total Air Temperature).....	9
2.2.2.4 Mach Sayısı.....	9
2.3 Aerodinamik Kuvvetler.....	10
2.3.1 Sıcaklık.....	11
2.3.2 Basınç.....	12
2.3.3 Yoğunluk.....	12
2.3.4 Viskozite.....	13
2.3.5 Ses Hızı.....	14
2.4 Uluslararası Standart Atmosfer.....	14
2.4.1 ICAO Standart Atmosferi.....	15
2.5 Uçak Performans Karakteristikleri.....	17
2.6 Uçak Yakıt Tüketimi.....	18
2.7 SIMMOD Yakıt Tüketim Modeli.....	19

2.8 Yapay Sinir Ağları Yardımıyla Yakıt Tüketimi.....	25
2.9 Yapay Sinir Ağlarına Giriş.....	25
2.9.1 Yapay Sinir Ağları Modelinin Temel Esasları.....	26
2.9.2 Ağ Mimarisi.....	29
2.9.3 Sinirler.....	30
2.9.4 Katmanlar.....	31
2.9.5 Katmanlar Arası Bağlantılar.....	31
2.9.6 Sinirler Arası Bağlantılar.....	32
2.9.7 Ağırlıklar.....	33
2.9.8 Hatırlama (Recall).....	33
2.9.9 Aktivasyon Fonksiyonları.....	33
2.9.10 Öğrenme ve Test Etme.....	36
2.9.11 Yapay Sinir Ağı Tipleri.....	36
2.9.12 Geri Yayınım Modeli.....	37
2.9.13 Levenberg-Marquardt Geri Yayınım Algoritması.....	42
3. METODOLOJİ.....	46
3.1 Test Uçağının Seçilmesi	46
3.2 Kara kutudan İlgili Parametrelerin Alınması.....	47
3.2.1 Kullanılan Kara Kutunun Tanımı.....	47
3.2.2 Kara Kutudan Bilgilerin İndirilmesi	47
3.3 Yapay Sinir Ağlarının Eğitilmesi.....	48
3.3.1 Uygulamanın Yapılacağı Programın Seçilmesi.....	48
3.3.2. Algoritmaların seçilmesi.....	48
3.3.4 Uygun Sinir Ağı Topolojisi Dizayını.....	49
3.4 Yapay Sinir Ağı Uygulaması.....	50
3.4.1 Kullanılacak Veri Tabanının Analizi.....	50
3.4.1.1 Taxiing Fazı.....	51
3.4.1.2 Take-off Fazı.....	51
3.4.1.3 Climb Fazı.....	52
3.4.1.4 Cruise Fazı.....	52
3.4.1.5 Descent Fazı.....	52
3.4.1.6 Landing Fazı.....	53
3.4.2 Yakıt Tüketim Modelinde Kullanılacak Sinir Ağının Tanımı.....	53

3.4.3 Özet.....	55
3.5 İstatistiksel Analizin Uygulanması.....	56
3.6 Sonuçların Uygulanması.....	57
4. MODELİN UYGULANMASI.....	60
4.1 Farklı Uçuş Fazları İçin Ağın Eğitimi	60
4.2 Eğitilen Ağın Kullanılması.....	63
5. SONUÇLARIN DEĞERLENDİRİLMESİ.....	65
5.1 Eğitim ve Test Sonuçları.....	65
5.2 Sinir Ağı Yardımıyla Yakıt Tüketim Sonuçları.....	72
6. SONUÇLAR VE TAVSİYELER.....	78
6.1 Sonuçlar.....	78
6.2 Tavsiyeler.....	79
KAYNAKÇA	81
ÖZGEÇMİŞ	83

ŞEKİLLER LİSTESİ

Şekil Adı:	Sayfa no:
Şekil 2.1: Kara Kutunun Uçak Üzerindeki Pozisyonu ve Veri Akışı.....	5
Şekil 2.2: Uçuş Verileri Kayıt Sistemi Komponent Şeması.....	7
Şekil 2.3: Uçağa Uygulanan Kuvvetler Diyagramı.....	11
Şekil 2.4: Çok Katmanlı Yapay Sinir Ağı.....	31
Şekil 2.5: Temel Yapay Sinir Ağı Hücresi.....	34
Şekil 2.6: Eşik Aktivasyon Fonksiyonu.....	34
Şekil 2.7: Doğrusal Aktivasyon Fonksiyonu.....	35
Şekil 2.8: Logaritma Sigmoid Aktivasyon Fonksiyonu.....	35
Şekil 2.9: İleri Beslemeli Yapı.....	37
Şekil 2.10: Genel Bir Yapay Sinir Ağları Mimarisi.....	38
Şekil 3.1: Uçağın Fiziksel Görünümü.....	46
Şekil 3.2: Uçuş Fazları.....	51
Şekil 3.3: Üç Katmanlı Genel Yapay Sinir Ağı.....	53
Şekil 3.4: Taksi Fazı Yakıt Tüketim Grafiği.....	54
Şekil 3.5: Take-off Fazı Yakıt Tüketim Diyagramı.....	54
Şekil 3.6: Climb Fazı Yakıt Tüketim Diyagramı.....	55
Şekil 3.7: Cruise Fazı Yakıt Tüketim Diyagramı.....	55
Şekil 3.7: Seçilmiş Sinir Ağı Mimarisi.....	58
Şekil 4.1: Eğitimde Kullanılan Uçuşun İrtifa ve Eğitim Noktalarını Gösteren Profil.....	62
Şekil 4.2: Yakıt Tüketiminin Tahmininde Kullanılan Uçuşun İrtifa ve Performans Noktalarını Gösteren Profil.....	63
Şekil 5.1: Take-off Fazı Test Grafiği.....	66
Şekil 5.2: Climb Fazı Test Grafiği.....	67
Şekil 5.3: Cruise Fazı Test Grafiği.....	68
Şekil 5.4: Descent Fazı Test Grafiği.....	69
Şekil 5.5: Landing Fazı Test Grafiği.....	70
Şekil 5.6: Climb Fazı Altitude ve Fuel Flow Grafiği.....	71
Şekil 5.7: Yakıt Tüketim Tahmini Yapılan Uçuşun Profili.....	72
Şekil 5.8: Take-off Fazı Yakıt Tüketim Tahmin Grafiği.....	73

Şekil Adı:	Sayfa no:
Şekil 5.9: Climb Fazı Yakıt Tüketim Tahmin Grafiği.....	74
Şekil 5.10: Cruise Fazı Yakıt Tüketim Tahmin Grafiği.....	74
Şekil 5.11: Descent Fazı Yakıt Tüketim Tahmin Grafiği.....	75
Şekil 5.12: Landing Fazı Yakıt Tüketim Tahmin Grafiği.....	76

TABLULAR LİSTESİ

Tablo Adı:	Sayfa no:
Tablo 3.1: Uçak Karakteristik Değerleri.....	47
Tablo 3.2: Optimizasyon Algoritmalarının Karşılaştırılması.....	48
Tablo 3.3: Yapay Sinir Ağı Topoloji Adaylarının Listesi ve Onlara Karşılık Gelen Sayısal Performanslar.....	49
Tablo 3.4: Uçuş Fazlarının Eğitim ve Test Verileri.....	56
Tablo 4.1: Giriş ve Çıkış Parametrelerinin Özeti.....	61
Tablo 5.1: Eğitim Data Setleri.....	65
Tablo 5.2: Take-off Fazı Eğitim Raporu 1.....	65
Tablo 5.3: Take-off Fazı Eğitim Raporu 2.....	66
Tablo 5.4: Take-off Fazı Parametrelerinin Korelasyon Analizi.....	66
Tablo 5.5: Climb Fazı Eğitim Raporu 1.....	67
Tablo 5.6: Climb Fazı Eğitim Raporu 2.....	67
Tablo 5.7: Climb Fazı Parametrelerinin Korelasyon Analizi.....	67
Tablo 5.8: Cruise Fazı Eğitim Raporu 1.....	68
Tablo 5.9: Cruise Fazı Eğitim Raporu 2.....	68
Tablo 5.10: Cruise Fazı Parametrelerinin Korelasyon Analizi.....	68
Tablo 5.11: Descent Fazı Eğitim Raporu 1.....	69
Tablo 5.12: Descent Fazı Eğitim Raporu 2.....	69
Tablo 5.13: Descent Fazı Parametrelerinin Korelasyon Analiz.....	69
Tablo 5.14: Landing Fazı Eğitim Raporu 1.....	70
Tablo 5.15: Landing Fazı Eğitim Raporu 2.....	70
Tablo 5.16: Landing Fazı Parametrelerinin Korelasyon Analizi.....	70
Tablo 5.17: Uçuşun Tüm Fazlarının MSE ve Standart Sapma Tablosu.....	72
Tablo 5.18: Take-off Fazı Yakıt Tüketimi Tahmin Raporu.....	73
Tablo 5.19: Climb Fazı Yakıt Tüketimi Tahmin Raporu.....	74
Tablo 5.20: Cruise Fazı Yakıt Tüketimi Tahmin Raporu.....	75
Tablo 5.21: Descent Fazı Yakıt Tüketimi Tahmin Raporu.....	75
Tablo 5.22: Landing Fazı Yakıt Tüketimi Tahmin Raporu.....	76

KISALTMALAR

ACMS	: Aircraft Condition Monitoring System
ADALINE	: Adaptive Linear Neuron
ADC	: Air Data Computer
AFBM	: Aircraft Fuel Burn Model
ARDC	: Air Reserch Development Command
ATC	: Air Traffic Controller
CVR	: Cockpit Voice Recorder
DFDR	: Digital Flight Data Recorder
EEPROM	: Electrically Erasable Programmable Read-Only Memory
FAA	: Federal Aviation Administration
FAR	: Federal Aviation Rules
FDAU	: Flight Data Acquisition Unit
FDR	: Flight Data Recorder
FDRS	: Flight Data Recorder System
FMS	: Flight Management System
HHDLU	: Hand Held Download Unit
ICAO	: International Civil Aviation Organisation
ICAN	: International Commision for Air Navigation
MAE	: Mean Absolute Error
MSE	: Mean Square Error
MSL	: Mean Sea Level
NACA	: National Advisory Commitee of Aeronatics
NMSE	: Normalized Mean Squared Error
NTSB	: National Transportation Safety Board
PCMCIA	: Personal Computer Memory Card International Association
RVSM	: Reduced Vertical Seperation Minimum
SSCVR	: Solid State Cockpit Voice Recorder
SSFDR	: Solid State Flight Data Recorder
TAT	: Total Air Temperature
TSFC	: Thrust Specific Fuel Consumption
ULB	: Underwater Locater Beacon

ÖZET

Wright Kardeşlerden başlayarak günümüzde ki süper sonik askeri uçaklara ve jumbo jetlerine kadar havacılık teknolojisinin gelişimi hızlı bir şekilde yükseliş gösterdi ve bu konuda beklentiler de arttı. Büyük rekabetlerin yaşandığı sivil hava taşımacılığında üreticilerin yanısıra operatörlerin de rakiplerine üstünlük kurma çabası piyasa şartlarını zorlaştırdı. Daima daha fazla hız, daha fazla menzil ve daha fazla yük taşıma kapasitesinin artırımına ihtiyaç duyuldu. Teknolojik teçhizat ve donanımların gelişiminin ana amacı; performansın artması ve maliyetin azalması olmuştur. Bu faktörlerin kesiştiği temel nokta ise yakıtın etkili kullanımudur. Uçağın, pistte ve havadaki hareketi esnasında harcadığı toplam yakıt miktarının saptanması hava taşımacılığı ekonomisi açısından çok büyük önem arz etmektedir. Tüketilen yakıt miktarının azaltılması, sistem içerisinde yer alan çeşitli uçakların yakıt tüketimindeki ve akışındaki profil ve prosedür bakımından özelliklerinin bilinmesiyle doğru orantılıdır. Bu nedenle sürekli değişen ve gelişen bu sektörde arayışlar bitmek bilmemektedir.

Bu çalışmada genel olarak uçak kazalarından sonra kaza nedeninin tesbiti amacıyla kullanılan ve bu nedenle; kara haberin habercisi olarak anılan kara kutunun genel kullanımının dışına çıkılmıştır. Kara kutudan indirilen uçuş bilgilerinden, ilgili parametreler alınarak yapay sinir ağları ile analizi yapılmış ve bir hava aracının tüm uçuş fazları için ayrı ayrı yakıt tüketimini tahmin eden bir model oluşturulmuştur.

ABSTRACT

Beginning from Wright Brothers till nowadays' supersonic military airplanes and jumbo jets, the improvement of aviation technology has increased rapidly and the expectations about this area has also increased. In the civil aviation transportation in which big rivalries take place, the struggles of the producers and operators in order to beat their rivals have made the marketing conditions more and more difficult. More speed, more range and more capacity for carrying things have always been needed. The main aim of the improvement of the technologic equipments and devices has been to increase the performance and decrease the costs. The main point in the intersection of these factors is the effective use of the fuel. Determining the total fuel consumption of the plane during its movement on the ground and in the air is considered as a very important factor for the air transportation economy.

Increasing the amount of fuel consumption has a direct proportion with identifying the features of the planes' fuel consumption and fuel-flow from the point of view of the profiles and procedures. Thus, the constantly changing and developing searches in this area has never come to an end.

The general use of black box –which is known as a messenger of bad news because of its use in identifying the cause of the accidents– has not been applied in this research.

After getting the flight informations from the black box, the parameters have been taken and analyzed with their artificial neural networks; then a new model which estimates the fuel consumption of an air vehicle for each flight phase one by one has been formed.

1. GİRİŞ

1.1 Tarihçesi

İlk etapta yakıtın ulaşılabilirliği ve maliyetinin yüksekliğinin, hava taşımacılığı endüstrisinin evriminde etkisi düşük olmuştur. Bugün hava taşımacılık şirketleri açısından havacılıktaki yakıt tasarrufu, şirket giderlerinin küçülmesinde en önemli faktörlerden biridir. 1970'lerin başları petrol kaynaklı yakıtın ucuzluğunun ve bolluk çağının sona erdiği yıllar olmuştur. Bu yıllarda yakıt maliyeti, hava taşımacılığı açısından daha fazla önem arz etmeye başlamıştır. 1973 yılında ticari jet yakıtının galon başı maliyeti 0,12 dolar idi. O yıl arap yakıt ambargosu piyasaları vurdu ve takip eden iki yılda hava yolları galon başı %300'lük bir fiyat artışıyla yüz yüze geldi. 1981 yılında fiyat 1,05 dolara kadar ulaştı. Altı yıl sonra, galon başı yakıt fiyatı 0,53 dolara geriledi. 1987 yılının sonunda fiyatlar önceki yıllardaki çıkış trendine tekrar ulaştı. 1990 yılında ticari yakıtın galon başı fiyatı 0,78 dolara yükseldi. 1994 mali yılı esnasında Federal Havacılık Dairesi'nin (FAA, Federal Aviation Administration) belirlediği yakıt fiyatları genel anlamda bir düşüş gösterdi. 1994 yılında yakıt fiyatları ortalama 0,55 dolar idi. Mevcut dolar piyasasındaki jet yakıtı fiyat tahminleri, geçen on iki yılda geçmiş yıllara benzer bir trend yakalayarak %4'lük bir artış gösterdi. Sivil havacılık yakıt fiyatlarının 1981 yılından beri bir düşüş göstermesine rağmen uçuş sayıları yıldan yıla artış gösterdi. 1995-2006 mali yılları arası FAA Havacılık Tahminleri teknik raporu, geçen on iki yılda ortalama ekonomik büyümenin reel yakıt fiyatlarıyla birlikte az bir enflasyonun gerçekleştiğini ve bununla birlikte havacılık hizmetlerinin hızlı büyümesinden kaynaklanan arz ile yakıt fiyatlarının orantılı olarak artış gösterdiğini bildirdi. Uçuş sayıları arttıkça yakıt ihtiyacı daha da arttı.

Ticari hava taşımacılığı endüstrisi, artan yakıt tüketimiyle alakalı olarak yakıt fiyatlarının artmasına karşın ekonomik pozisyonu korumak ve ayakta durabilmek için çaba sarfetmek durumunda kalmıştır. 1990'ların ortalarındaki ticari hava yakıt tüketimi baz alınarak Amerika Birleşik Devletlerinde ticari hava taşımacılığı tarafından yılda 12 milyar galon yakıtın tüketildiği göz önünde bulundurulursa yüzde bir oranındaki bir etkili yakıt kullanımı sağlanabilirse bu; yılda yüz yirmi milyon galon yakıt tasarrufu yapılması anlamına gelmektedir. FAA'nın etkili yakıt kullanım araştırmalarındaki çabalarının arkasındaki temel motivasyon faktörü hava taşıma

sistemindeki dramatik fiyat artışıdır. Gelişmiş sistem etkinliğini sağlamak için gereken temel faktör uçak işletmesindeki etkili yakıt tüketimini sağlama becerisidir (Schilling,G. 1997).

1.2 Araştırmaya Yaklaşım ve Amacı

Yukarıdaki tarihsel gerçeklerden yola çıkarak uçak yakıt tüketiminin modellenmesinin hava ulaşım işletmelerinde önemli bir gereksinim olduğu sonucuna ulaşılabilmektedir. Sebep basittir; yakıt tüketim modelinin gelişimi belirli koşullar altında uçak performansını oluşturur. Bir kere bu koşullar bilindiğinde en etkili yakıt akış oranını bulma işlemine karar verilebilir. Mesela, bir operatör şirket yakıt tüketim modelini kullanarak, Boeing 747-100 uçağını 45,000 feet yüksekliğinde (FL450) yolculuk yaparken Mach 0.84'de uçurmaktan ziyade 45,000 feet (FL450) irtifasında Mach 0.86'da uçurmanın, modelin sonucuna göre daha ekonomik olduğunu görecektir (Schilling,G. 1997). Zamanın büyük bir rekabet unsuru olduğu sektörde daha fazla hızla, daha kısa zamanda ve daha az yakıt tüketebilecek iken, yavaş gidildiğinde yakıt tüketiminin daha düşük olduğunu öne süren firmanın hem varış süresi uzar, hem de tükettiği yakıt miktarı daha fazla olacaktır.

Genel olarak yavaş giden araçların daha az yakıt tükettiğine inanılır fakat yakıt tüketiminin tek bir hıza değil aksine pek çok unsura bağlı olarak değiştiği görülmüştür ve bunun doğrusal olmayan bir hareketi vardır.

Bu araştırmanın amacı; esnek, hesapsal olarak etkili ve hata oranının düşük olduğu bir uçak yakıt tüketim modeli geliştirmektir. Geliştirilen modelde bilgi kaynağı olarak uçaklar üzerinde bulunan kara kutudan indirilen bilgiler kullanılacaktır. Veri girişleri buradan alınan parametrelerle yapılacaktır. Modelin sonunda elde edilen çıkış ise yine kara kutuda mevcut olan yakıt akışı (fuel flow) bilgisi olacaktır. Model sonucunda bulunan veri ile uçağın kaydını tuttuğu gerçek veri kıyaslanacaktır.

Ticari hava taşımacılığı şirketleri, üretici firmalara uçak siparişi verirken uçağın Uçuş Yönetim Sistemindeki (FMS, Flight Management System) rom bellek orada programlanarak gönderilmektedir. Bu programlama da şirketin hangi prensiple uçağını belirtmesi istenmektedir. Bir şirket uçaklarını kendi prensipleri doğrultusunda ya zaman ekonomisi ya da yakıt ekonomisi üzerine uçurmak istemektedir. Bu şirketler kar amaçlı kuruluşlar olduklarından, petrolün ucuz olduğu Arap Ülkeleri haricinde genellikle yakıt ekonomisi tercih edilmektedir.

Bu model ile uçağın hangi irtifalarda ve hangi şartlar altında, ne kadar hızda ne kadar yakıt tükettiği tahmin edilebilecek ve bunun sayesinde eldeki optimum değerlerle kullanıcı için en uygun olan hava aracı uçuş profili çıkartılabilecektir.

Yakıt tüketiminin tonlarca olduğu düşünülürse, bu maliyetin azaltılmasının sivil hava taşımacılığı şirketleri açısından çok önemli olduğu görülecektir. Bu model ile uçağın yerdeki hareketi (taksi fazı) ve sonrasında kalkıştan inişe kadar olan tüm uçuş bölümleri hesaplanarak toplam yakıt tüketimini tahmin ederek ona göre hava aracına yakıt yüklemesi yapılabilecektir. Çünkü, fazladan yüklenen her bir kilo ağırlık yakıt tüketiminin artmasına neden olduğundan maliyetin artması manasına gelecektir.

2. LİTERATÜRÜN İNCELENMESİ

2.1 Giriş

Literatürün incelenmesi bölümünün amacı, araştırmada geçecek olan temel kavramların burada sunulurken okuyucunun aydınlatılmasıdır. Bu bölümde, ilk etapta kara kutu ve uçuşla ilgili terimler, daha sonra havacılık ve havacılıkta yakıt tüketimi ile alakalı konular ve son olarak yapay sinir ağlarının esasları ele alınacaktır.

2.2 Uçak Verileri Kayıt Sistemi (FDRS)

Kara kutular, genellikle uçakların kuyruk bölümüne yerleştirilen kayıt cihazlarıdır. Askeri, ticari tüm uçaklarda ve özel uçaklarda kullanılabilir. Hava taşımacılığı yapılan uçaklarda Federal Havacılık Dairesi (FAA, Federal Aviation Administration) iki tür veri kaydedici kullanma zorunluluğu getirmiştir. Giderek aynı kutu altına alınan bu iki kayıt cihazından biri Uçuş Data Kaydedici (FDR, Flight Data Recorder) ve diğeri Kokpit Ses Kaydedici (CVR, Cockpit Voice Recorder)'dir.

FDR'lar bir çok uçuş parametrelerini kaydederken, CVR'lar uçuş ekibinin radyo sistemleri ve intercom üzerinden yaptığı tüm konuşmaları ve kokpitteki tüm sesleri kaydeder.


Teknolojik ilerlemeler kara kutuların bir evrim sürecinden geçmesini sağladı. 1958 yılında FDR'lar piyasaya ilk çıktığında kayıt ortamı olarak nikel içerikli paslanmaz çelik bantlar kullanılmakta idi. 6 ila 10 arasındaki kısıtlı sayıdaki verilerin yaklaşık şekli bu bantın üzerine küçük uçaklarda 8, büyük gövdeli uçaklarda 24 saat süreyle çizilmekteydi.

Bu cihazların içindeki metal bantların değiştirilme gerekliliğinin yanısıra kaydettikleri verilerin analizi oldukça zordu. 1983 ile 1986 yılları arasında 75 uçağın maruz kaldığı kaza veya olaylarda, uçaklarda bulunan metal bantlı FDR'lar üzerinde yürütülen bir araştırmada Ulusal Ulaşım Güvenlik Kurulu (NTSB, National Transportation Safety Board), bu cihazların yüzde 48'inde ilgili bilgilerin kaydedilme ve okunma arızalarının olduğunu belirlemiştir. Bunun yanı sıra verilerin yeterince hassas olarak kaydedilememesi, okuma yapılırken bir inch'in yüzde biri kadar sapma olasılığı FAA'nın 1987 yılında Amerika'da ki (Part 121 gereği) havayolu uçaklarında metal bant FDR'ların kullanılmasının yasaklanmasını ve bu tiplerin yerine manyetik bant üzerine 24 saat kayıt yapan Dijital Uçuş Data Kaydedici (DFDR, Digital Flight Data Recorder)'lere bırakmasını istemiştir. (B727

uçaklarında yakın bir zamana kadar kullanılan bu tipler SSFDR'larla değiştirilmiştir.)

Dizaynına göre 200 civarında veri kaydedebilen DFDR'lardan data okunması daha kolay ve güvenilirliği daha fazladır. Veriler, dijital formata sahip sonsuz döngülü bir bant üzerine 25 saat süreyle kaydedilmektedir. Bu cihazların okunabilirliği ve güvenilirliği yüksek, bakımları daha kolay ve ucuzdur. Bu tip DFDR'ler RJ, B737-400/500 ve A310 uçak tiplerinde kullanılmaktadır.

Şekil 2.1: Kara Kutunun Uçak Üzerindeki Pozisyonu ve Veri Akışı



Gelişen teknoloji, bakım masraflarını daha aşağı çeken, kaydedilebilen veri sayısını arttıran, güvenilirliği daha yüksek, okuma kolaylığı daha iyi olan SSFDR'ların üretilmesine imkan sağlamıştır. 1990 yılından bu yana üretilen SSFDR'lar (Solid State Flight Data Recorder), kayıt cihazlarının Solid State modelleridir ve kayıt ortamı olarak EEPROM çiplerini kullanırken dizayn amacına göre 1300'e yakın veri kaydederler. Bu tipler A340, A330, A320 serisi, B737-600/700/800/900, B727 gibi uçaklarda kullanılmakla birlikte B737-400/500 ve A310 uçaklarında da tercih edilmektedir.

FDR'a kayıt edilmesi gerekli bilgiler uçaktaki sensörlerden ve kompütürlerden öncelikle Uçuş Data Toplama Ünitesi (FDAU, Flight Data Acquisition Unit)'ne gider. FDAU'den iki fazlı Harvard PCM hattı üzerinden 768 bit/sec 64 word/sec hızıyla bilgiler FDR'ye gönderilir.

Teknolojik gelişmeler CVR üretimini de etkilemiş ve 1965'te analog ses bilgisini, sonsuz döngülü standart kaset tipli bir banda 30dk süre ile kaydeden kayıt cihazları daha sonra, dijital formatta 2 saatlik ses kaydını yapan SSCVR (Solid State Cockpit Voice Recorder) formatına dönüşmüştür. 30 dakikalık ses kaydı için 27 megabaytlık memory, 2 saatlik kayıt için ise 82 megabayt gerekmektedir. Yeni üretilen uçaklarda bu son ürünler kullanılırken, eski uçaklarda CVR ve DFDR'lar halen kullanılmaktadır. CVR'ın dört adet mikrofon girişi vardır. Bunlardan birincisi kokpitteki başüstü panele yerleştirilmiştir. Bu sayede korna sesleri, motor ve diğer dış sesler kaydedilebilir. Diğer bir giriş sayesinde kulaklıklardan alınan sesler (pilot, yardımcı pilot ve uçuş mühendisi için) kaydedilir. Diğer girişler ile de digital bilgiler (voice data) kaydedilmektedir.

Uçağa enerji verilir verilmez kaydetmeye başlayan kara kutular, güç kesildikten 5 dakika sonra kaydı tamamlarlar. Bu noktada yukarıda açıklandığı gibi, takılan cihazın özelliğine göre uçağın son 25 saatlik verilerine ve son 30 dakika veya 2 saatlik kokpit ses kayıtlarına ulaşılabilir.

Cihazlar 1100 °C sıcaklığa yarım saat, 260 °C'ye on saat, 3400 G'lik bir çarpma kuvvetine 6 milisaniye, uçak yakıtına 48 saat dayanıklıdır. Ayrıca 3 metreden düşen 225 kg'lık bir ağırlığa karşı dirençlidir.

Herhangi bir kaza anında uçak karaya düşmüş ise, kara kutular üzerindeki beyaz yansıtıcı şeritler sayesinde daha kolay bulunabilir. Uçağın suya düşmesi durumunda ise kayıt cihazlarının üzerinde takılı olan Sualtı Konum Bildirici (ULB, Underwater Locater Beacon)'ler 20000 feet de 30 gün süreyle yaklaşık 37,5 Khz frekansla yayın yaparak kara kutuların bulunmasını sağlar.

Günümüzde hava taşımacılık uçaklarında bulunan kayıt cihazları sayesinde büyük kazaların arkasında yatan esrarengiz durumları aydınlatmak sorun olmaktan çıkmıştır. Pilotlar ile Hava Trafik Kontrolörleri (ATC, Air Traffic Controller) arasında geçen konuşmaların kaydedildiği ses kaydedicileri yardımı ile araştırmacılar, neyin yanlış gittiğini saniye saniye inceleyerek, şaşılacak kadar ayrıntıyı bir araya getirebilmektedirler.

Regülasyonlar kayıt edilen veri sayısını artırma dursunlar, tüm kayıt bilgileri ile kaydediciler daha güvenli uçuşları bir gerçek haline getirmek için bilgi sağlamaya devam etmektedirler (www.uted.org).

2.2.1 FDRS Komponentleri


Şekil 2.1’de de görüldüğü üzere uçak üzerinde ki sistem ve sensörlerden gelen veriler uçağın elektrik&elektronik kompartımanındaki FDAU (Flight Data Acquisition Unit) komponentinde toplanır. FDR, depoladığı veri kayıtlarını bu komponentten alır.

Uçuş Verileri Kayıt Sistemi (FDRS, Flight Data Recorder System) aşağıdaki komponentlere sahiptir:

- Uçuş Veri Kaydedici (FDR)
- Uçuş Verilerini Alma Ünitesi (FDAU)
- FDAU Durum Rölesi
- Uçuş Kaydedici Test Modülü
- Akselerometre
- Uçuş Kontrol Sensörleri
- Uçuş Kumanda Yüzeylerinin Pozisyon Sensörleri
- Sistem Test Konnektörleri
- Program Yönlendirme Modülü

Şekil 2.2’ de FDRS sisteminde ki komponentlerin bir kısmı ve bunların birbiri ile ilişkisi görülmektedir.

Şekil 2.2: Uçuş Verileri Kayıt Sistemi Komponent Şeması



FDRS durumunu ve rapor çıktıları almak için yazıcı kullanılır.

ACMS (Aircraft Condition Monitoring System) bilgisi FDAU'dan veri yükleme kontrol paneli aracılığıyla bir Veri Yükleyici (Data Loader)'ye alınır. Veri yükleyici aldığı verileri bir diske kopyalar. Veri yükleme kontrol panelinden ACMS transfer seçeneği seçilmelidir.

Kara kutu, uçakta motorlardan birisi çalıştığında veya uçak havada iken otomatik olarak kayıt etmeye başlar. Ayrıca yerde TEST/NORMAL anahtarı TEST konumuna getirildiğinde de çalışır.

Kara kutunun giriş sinyalleri uçaktaki pek çok sistem ve sensörden gelir. Kara kutunun önünde suya duyarlı ve su altında iken pozisyonun belirlenmesini sağlayan bir batarya bulunur (Boeing AMM, a).

2.2.2 FDR Parametreleri

Daha önce de bahsedildiği gibi CVR da ses kayıtları saklanırken, FDR'da ise uçuşla alakalı veriler kayıt altına alınır. Her uçak modelinde depolanan veri sayısı birbirinden farklıdır. Yeni nesil uçaklarda saklanan veri sayısı dört rakamla ifade edilebilir hale gelmiştir. Bu araştırmada incelenecek olan Boeing 737-800 model uçağın kayıt altında tuttuğu parametre sayısı 920 tanedir. Bu parametrelerden sadece üzerinde işlem yapılacaklara burada değinilecektir.

2.2.2.1 Airspeed

Airspeed, bir uçağın havaya göre hızıdır. Hava hızı pek çok farklı şekillerde ölçülür. Bunlar;

- Indicated Airspeed (Gösterilen Hava Hızı)
- Calibrated Airspeed (Kalibre Edilmiş Hava Hızı)
- Equivalent Airspeed (Eşdeğer Hava Hızı)
- True Airspeed (Gerçek Hava Hızı)

Uçuş esnasında kokpitte bir gösterge aracılığı ile gösterilir. Bu gösterge doğrudan dışarıdan gelen hava basıncı (dinamik basınç) ile uçağın hareketinin, atmosfer basıncını etkilemediği uçak üzerindeki bir bölgeden alınan hava basıncının (statik basınç) farkını alarak bunu kokpitte okumaya sunmaktadır. Dinamik hava basıncının uçak içine alınmasını sağlayan parçaya "pitot tube" denmektedir. Pitot tube'ün pozisyonun seçilmesi çok önemlidir. Ölçümlerin doğru olabilmesi için uçağın pervanesinden veya etrafındaki bozuk hava akışından etkilenmemelidir. Bu yüzden genelde uçağın burun kısmında sağ ve sol taraflarda kokpit penceresinin alt kısmında bulunurlar. Ayrıca hava hızının ve irtifanın ölçümü için statik hava basıncının

alındığı statik portlar da bulunmaktadır. Bunlar genelde birden fazladır ve yine buruna yakın gövdenin sağ ve sol taraflarına yerleştirilmişlerdir (Wikipedia, a).

2.2.2.2 Altitude

Bir cismin bilinen bir yüzey veya referans noktasından ayrılarak, yükselmesi ve alçalması sonucu o referans noktasına göre kazandığı yüksekliğe irtifa denmektedir. Havacılıkta genelde referans noktası olarak ortalama deniz seviyesi (MSL, Mean Sea Level) kullanılır ve irtifanın birimi “feet” olarak alınır. İrtifa ölçen cihazlara “altimetre” adı verilmektedir.

Atmosferik basınç düştükçe irtifa artmaktadır. Bu prensibe dayanılarak barometrik altimetrelere yapılmıştır. Hava araçlarında da kullanılan barometrik altimetrelere statik portlardan aldığı atmosfer basıncını kullanarak irtifayı tespit ederler.

Uçaklar ayrıca belirli bir yüksekliğe kadar irtifa hesabında radio altimetrelere kullanırlar (yaklaşık 2500 feet). Bu altimetre, irtifa hesabı için radyo sinyalleri kullanır. Verici anten (transmitter antenna) ile yere gönderdiği sinyalin yere çarpıp geriye yansması sonucu alıcı anten (receiver antenna) tarafından alınır ve bu sinyalin gidiş geliş süresi hesaplanır. Hız-zaman denklemleri kullanılarak uçağın yer ile olan mesafesi hesaplanır (Wikipedia, b).

2.2.2.3 TAT (Total Air Temperature)

Total Air Temperature, genelde havacılıkta kullanılan bir terimdir. Özel olarak dizayn edilmiş ve uçağın burun tarafına yakın olmak üzere gövdenin alt kısmına monte edilmiş bir sıcaklık probu (TAT probe) ile ölçüm yapmaktadır. Bu prob dizaynı gereği dışarıdaki hareketsiz havayı içeri getirir. TAT probundan giren hava, ADC (Air Data Computer)’lerde hesaplanarak değer kokpitte sistem göstergelerinde görüntülenir. TAT sıcaklığı genelde, statik sıcaklıktan daha yüksek bir değer gösterir (Wikipedia, c)

2.2.2.4 Mach Sayısı

Mach (Ma) sayısı, hareket halindeki bir kütlenin hızının, kütlenin bulunduğu şartlardaki ses hızına oranıdır. Kısaltması “Ma” ya da “M”dir. Adını Avusturyalı fizikçi ve filozof Ernst Mach'tan alır. Ernst Mach'tan önce bu konu üzerine Fransız fizikçi Sarrau'da incelemeler yaptığından Sarrau Sayısı da denir.

$$M = \frac{V}{a}$$

Örneğin, deniz seviyesinde, 1 atm basınçta ve 15 ° C hava sıcaklığında 1 Mach = 1226,5 km/sa olarak belirtilir. Yerde ses hızı göğe oranla daha yüksek değerdedir.

Yerden yükseldikçe hava sıcaklığı düşer (stratosfer sınırına kadar). Ses hızının karesi hava sıcaklığı ile doğru orantılı olarak değiştiğinden, yerden yükseldikçe ses hızı azalır. Buna bağlı olarak da o yükseklikteki mach sayısı deniz seviyesine göre daha az olur.

Örneğin, stratosfer sınırında 1100 metrede 1 Mach=1062,2 km/s'dir. (Wikipedia,d)

2.3 Aerodinamik Kuvvetler

Bir uçuşun gerçekleşebilmesi için hava aracının ağırlığı ve kaldırma kuvvetleriyle ilgili denklemlerin dengede olması gereklidir. Hava aracının yeryüzünün kendi etrafında dönmediği varsayımından yola çıkarak kanatlarının durumu (hucum açısı, akışkanlık, sıfır yaklaşma açısı) ve yüzey mukavemeti olmaksızın havanın içerisinde hareket ettiği kabul edilir.


Düz bir uçuş esnasında hava aracının hareketi;

- Ağırlık
- Motorlar tarafından sağlanan itki kuvveti ve
- Hava akışından kaynaklanan aerodinamik kuvvetler

tarafından belirlenir.

Uçuş performansını etkileyen önemli diğer bir faktör ise hava aracının dinamik atmosfer şartlarında hareket ediyor olmasıdır. Normalde irtifa, yer yüzeyinden dikey uzaklık olarak düşünülür. Halbuki hava aracının operasyonu geometrik yükseltiden çok uçuş esnasındaki hava şartlarına bağlıdır. Böylece irtifa, standart atmosferin bir terimi olarak belirlenir. Havanın standart olduğu varsayıldığı zaman, havanın deniz seviyesindeki değerleri kabul edilir. Geriye dönüp bakıldığında, bunun gerçek uygulamalarda oluşması neredeyse imkansızdır. Verilen bir irtifada umulanın aksine hava bazen daha sıcak veya soğuk olmaktadır. Hava sistemleri, standart atmosfer şartlarında verilen irtifadan daha yüksek veya daha düşük olmasına sebep olduğundan dolayı devamlı değişmektedir. Hava aracının performans analizini yapmadan önce atmosfer şartlarını bütün yönleriyle anlaşılması çok önemlidir.

Şekil 2.3: Uçağa Uygulanan Kuvvetler Diyagramı



Hava için fiziksel değerler sıcaklık, basınç, yoğunluk, akışkanlık ve ses hızıdır. Atmosferik değişimlerden dolayı uçuş zarfındaki tüm irtifalarda koşulları günden güne ve doğal olarak tespit etmek gereklidir. 1962 yılında komite, standartlaştırılmış atmosferin teorik karakteristiklerini belirledi. Amaç, dünya çapında hava aracı sertifikasyon kriterleri belirlemektir (Schilling,G. 1997).

2.3.1 Sıcaklık

Deniz seviyesinde atmosferin sıcaklığı yaklaşık olarak 59.0°F (15.0°C)'dir. Başlangıçta sabit bir oranda olmak üzere, artan irtifa ile yaklaşık 36000 feet'lik irtifalara kadar sıcaklıkta bir düşme gözlenir. Sıcaklığın irtifaya bağlı olarak azaldığı bu bölgeye troposfer adı verilir. Bu bölgede uçan bir hava aracının göstergeleri her 1000 feet için yaklaşık 2.0°F değişim gösterir. Troposfer (FL360) irtifasını aşınca stratosfer tabakasına geçilir. Bu tabakanın sıcaklığı -69.7°F (-56.5°C)'dir. Bu katmanın alt taraflarının sıcaklığı neredeyse sabittir. Logaritmik değişim 75,500 feet (23 km) irtifaya kadar devam etmektedir. Atmosferin üst sınırı 45,000 feet (13.7 km)'dir. Stratosferin alt kısmında atmosferin özellikleri görülmez (Schilling,G. 1997).

2.3.2 Basınç

Deniz seviyesinde havanın basıncı $2,116.22 \text{ lb} / \text{ft}^2$ ($1.01325 \times 10^5 \text{ N} / \text{m}^2$)'dir. Durağan bir akışkan için basınç belirli bir noktaya etkiyen ağırlıktır. Deniz seviyesinden irtifa arttıkça basınç iki atmosfer katmanı arasında yavaş bir şekilde azalır. Troposfer katmanının sonunda basınç deniz seviyesindeki değerinin %20'si olmaktadır. Basınç değişikliği yoğunluktaki değişiklik oranındadır (Schilling,G. 1997).

2.3.3 Yoğunluk

Deniz seviyesindeki standart hava yoğunluğu $0.0765 \text{ lb} / \text{ft}^3$ ($1.225 \text{ kg} / \text{m}^3$)'dir. Havanın yoğunluğu irtifa arttıkça azalır. Bu ilişkiyi anlamak için irtifanın fonksiyonu olarak yoğunluğu ifade eden iki formül geliştirilmiştir. Hava gazlardan müteşekkil olduğundan birinci denklem yoğunluğa (ρ), sıcaklığa (T°) ve basınca (p) bağlı olarak şu şekildedir:

$$p = \rho RT^\circ \quad (2.1)$$

R dünyanın her yerinde sabit olan bir katsayıdır. İkinci denklemde atmosferin ağırlığı; irtifanın değişiminin, basıncın değişim oranına eşit olduğundan şu şekilde yazılır:

$$\frac{dp}{dh} = -\rho g \quad (2.2)$$

Formülde g yer çekimi ivmesidir. Havaya etkiyen tüm kuvvetlerin dengede olduğu varsayılmaktadır. Statik basınç denkleminde dikey kuvvetlerin toplanması halinde denklem şu şekilde olur:

$$\frac{d\rho}{\rho} = \frac{dp}{p} - \frac{dT^\circ}{T^\circ} \quad (2.3)$$

“(2.1)” ve “(2.2)” denklemlerinin birleştirilmesiyle:

$$\frac{d\rho}{\rho} = -\left(\frac{g}{RT^\circ} + \frac{1}{T^\circ} \frac{dT^\circ}{dh}\right)dh \quad (2.4)$$

Bir önceki denklem basitleştirilmiş haliyle şu şekilde ifade edilebilir:

$$\frac{d\rho}{\rho} = -\beta dh \quad (2.5)$$

Denklemdaki β , “(2.4)” denklemindeki parantez içindeki değeri ifade eder ve irtifaya karşılık gelmektedir. Yoğunluk için bu diferansiyel yapı kullanılırsa; atmosfer, bölgesel ekspanansiyel atmosfer olarak ifade edilir. Denklemdaki

β katsayısı irtifadaki küçük artışları içerebilir. Bu durumda stratosfer şartlarında yoğunluk fonksiyonu şu şekildedir:

$$\rho = \rho_o e^{-\beta h} \quad (2.6)$$

ρ_o referans seviyesindeki yoğunluk ve h bu seviyede ölçülen irtifadır. Daha önce stratosfer tabakasının alt taraflarında sıcaklığın sabit olduğu ifade edilmişti. Bundan dolayı, $\beta = g/RT$ denklemi eğer irtifaya bağlı olarak g yerçekimindeki değişimler ihmal edilirse sabit katsayı sayılır. Troposfer tabakasında T irtifanın doğrusal fonksiyonu olduğundan β irtifanın fonksiyonudur. Bazı bilim adamları her iki katman için de “(2.6)” denkleminde ifade edilen eksponansiyel atmosfer modelinin daha uygun olduğu görüşündedirler.

Collins (1984) tarafından kullanılan atmosfer modeli, basınç ve yoğunluğa bağlı olarak yukarıdaki denklemlerle arasında ilişkilendirilmiştir. Sabit sıcaklık eğimi için “(2.5)” denkleminde dT/dh değiştirilirse ve deniz seviyesindeki değerlerle bütünleştirilirse Troposfer modeli şu şekilde olur:

$$\rho = \rho_o \left(1 + \frac{T_o}{T_o} h\right)^{-\frac{1}{T_o}(g/R+T_o)} \quad (2.7)$$

Bu denklem statosferde standart atmosfere göre, irtifaya bağlı olarak yoğunluktaki değişim kanununu ifade etmektedir (Schilling, G. 1997).

2.3.4 Viskozite

Viskoziteyi anlamak için sıvıların akışkanlığını incelemek gerekir. Viskozitesi yüksek sıvılar; yavaş hareket eden, katı ve yapışkan bir özellik gösterir. Düşük viskoziteli sıvılar az yapışkan ve kolay hareket etme eğilimindedir. Viskozite, akışkanın hareketine bağlı olarak içerisinde dağılmış olan teğetsel gerilimdir. Bundan dolayı özellikle sıvı, bir taşıtın yüzeyinden akıyorsa hız gradyanı mevcuttur. Bu viskoz geriliminin hız gradyanına oranı olarak ifade edilen dinamik viskozite μ ile ölçülür. Deniz seviyesindeki standart sabit viskozite 1.2024×10^{-5} lb/ft-sec (1.7894×10^{-5} N-s/m²)'dir. Troposfer tabakasında irtifaya bağlı olarak μ katsayısı sıcaklık azaldıkça azalır. Stratosfer tabakasında değeri sabittir. Nihai formül şu şekildedir:

$$\frac{\mu}{\mu_o} = 0.081480723 \frac{T_o^{3/2}}{T_o + 110.4} [N - s/m^2] \quad (2.8)$$

μ ile havanın yoğunluğuna oranına “kinematik viskozite” denir.

$$v = \frac{\mu}{\rho} \quad (2.9)$$

2.3.5 Ses Hızı

Ses hızı, herhangi bir uçağın performansının değerlendirilmesinde esas rölü oynar. Ses hızının hesaplanması, momentum ve süreklilik denklemlerine dayanır. Durgun sıkıştırılamaz akışkanlar için sürtünmesiz akışkan akışının değişken bir alana akmasında, hız ve yoğunluk ilişkisi şu şekilde yazılabilir.

$$\rho_1 A_1 V_1 = \rho_2 A_2 V_2 \quad (2.10)$$

Momentum denklemi, Newton'un ikinci hareket yasasındaki momentum değişim oranının, kuvvet tabanı ile ilişkisine bir açıklamadır. Kuvvet, zamana bağlı olarak değişen hızın kütle ile çarpımına eşittir. Bir akışkan element için, bazı cebirsel işlemlerden sonra, basınçtaki değişim farkını aşağıdaki gibi yazabiliriz:

$$dp = -\rho V dV \quad (2.11)$$

Bu denklem momentum denkleminde elde edilmiştir. Yukarıdaki iki denklem ve ses dalgalarının izentropik olduğu farz edilerek aşağıdaki denklem bulunabilir:

$$a = \sqrt{\left(\frac{dp}{d\rho}\right)_{isentropic}} = \sqrt{\gamma RT} \quad (2.12)$$

Burada; R : gaz sabiti, ve T : sıcaklık oranıdır (Ertaş,S. 2004).

2.4 Uluslararası Standart Atmosfer

Standart atmosfer, bütün atmosferin veya daha geniş bir alan üzerindeki atmosfer parçasının ortalama şartlarını gösterecek şekilde hazırlanmış farazi bir atmosferdir. Standart atmosferler, altimetrenin kalibrasyonu, uçak performans hesapları, uçak ve roketlerin dizaynı, balistik tablolar gibi amaçlar için hazırlanır. Çeşitli atmosfer tipleri bulunmaktadır. Bunlara örnek vermek gerekirse;

- ICAN Standart Atmosferi (International Commission for Air Navigation)
- NACA Standart Atmosferi (National Advisory Committee of Aeronautics)
- ARDC Standart Atmosferi (Air Research Development Command)
- ICAO Standart Atmosferi (International Civil Aviation Organisation)

Havacılıkta kullanılan; ülkemizin de üyesi bulunduğu ICAO (Uluslararası Sivil Havacılık Örgütü) tarafından tanımlanan standart atmosferdir (Ertaş,S. 2004).

2.4.1 ICAO Standart Atmosferi

Hava araçlarının dizaylarındaki hesaplamalar; cihazların kalibrasyonu, altimetrik basınç hesaplamaları, belirli durumlarda uçakların performansları ve genel davranışlarını belirlemek ve birbirleri ile mukayese edilebilmelerini sağlamak amacıyla ICAO tarafından uzun yıllar boyunca yapılan rasatlardan elde edilen ortalama değerlere göre hazırlanarak yayınlanan değer ve tablolarıdır.

Hava aracı üreticileri, uçuşu etkileyen bütün parametreleri de kapsayan matematiksel modeller kullanırlar. Bu parametreler kısaca hava aracının özel şartlar altındaki performansı ve genel hareketini belirlerler. Ayrıca, hava araçlarının operasyonu için hazırlanan her türlü “Aletle Alçalma Usulünün” tasarımı sırasında da bu parametrelerden (hız ve atmosferik basınç gibi) yararlanılmaktadır.

Bir hava aracının uçuşu temel olarak 4 faktöre bağlıdır;

- Hava aracının toplam ağırlığı (Weight, W)
- Uçağın kaldırma gücü (Lift, L)
- Sürtünme, Sürüklenme (Drag, D)
- Hareket gücü, itki (Thrust, T)

Belirli bir irtifadaki havanın yoğunluğu, hava aracının uçuş performansını belirleyen kaldırma (Lift) ve sürtünme (Drag) bileşenlerini direkt olarak etkilemektedir. Başka bir deyişle, taşıma kapasitesi, uçuş tavanı, yakıt kapasitesi, menzil ve hız gibi operasyonu yakından ilgilendiren tüm özellikler havanın yoğunluğu ile bağlantılı olarak değişmektedir. Son olarak, hava basıncı, hava trafiğinin idaresi için son derece önemli olan dikey mesafenin belirlenmesini etkiler ki, hava araçları arasında dikey ayırmanın (vertical separation) sağlanması tamamen bu sayede gerçekleşmektedir.

ICAO standart atmosferi; basınç ve hızla ilgili (altimetre, machmetre, pitot tübü gibi) hava aracı parçalarının üretimi, geliştirilmesi ve kalibrasyonu ile hava aracının dizaynı ve test edilmesi amaçları ile hazırlanmıştır.

ICAO standart atmosferinin özellikleri:

- a) Standart atmosfer tamamen kuru olarak kabul edilmiştir.
- b) Fiziksel sabitler:

Ortalama deniz seviyesinde havanın fiziksel özellikleri:

- Sıcaklık : 15 °C
- Basınç : 1013.25 hPa'dır (29.92 inch)

- Yoğunluk :1.225 Kg/m³

c) Troposferin yüksekliği : 11 Km (MSL)

d) Troposferdeki sıcaklık : - 56.5 °C

e) Sıcaklığın ve basıncın yükseklikle değişimi (lapse rate):

Lapse rate: Bir fiziksel büyüklüğün bir diğer fiziksel büyüklüğün artışına göre değişimidir.

Hava sıcaklığının yüksekliğe bağlı olarak değişim oranı sabittir. Bu oran, ortalama deniz seviyesine göre sıcaklık/yükseklik değişimi oranı (Lapse Rate) (°C/Km)

- 5 Km* / 11 Km -6.5 (azalır)

11 Km / 20 Km 0 (sıcaklık yükseklikle değişmez, - 56.5 °C sabit kalır)

20 Km / 32 Km 1.0 (artar)

32 Km / 47 Km 2.8 (artar)

47 Km / 51 Km 0 (sıcaklık yükseklikle değişmez, - 2.5 °C sabit kalır)

51 Km / 71 Km -2.8 (azalır)

71 Km / 80 Km -2.0 (azalır)

* Ortalama deniz seviyesinin altında olarak ifade edilebilir.

Bu tabloyu sivil havacılıkta kullanılan seviyeler dikkate alındığında aşağıdaki şekilde sadeleştirebiliriz.

Yükseklik (MSL)	Sıcaklık değişimi	Basıç değişimi
31000 feet'e kadar	-1.98 °C/1000 ft	-1 hPa / 27 ft
31000 feet'in üzerinde	0 °C/1000 ft	-1 hPa / 50 ft

Önemli not: Pratik hesaplamalarda bu oranlar;

- sıcaklık için : - 2°C / 1000 feet

- basınç için : - 1 hPa / 30 feet

olarak kullanılmaktadır.

Yukarıdaki değerlerden de anlaşılacağı üzere, basıncın yükseklikle değişimi 31000 feet'in (MSL) altında, 31000 feet'in üzerindeki nazaran 2 kat daha çok olmaktadır. Bu farklılaşma, hava araçları arasında 1000 feet olarak uygulanmakta olan dikey ayırmanın, 29000 feet ve üzerinde 2000 feet'e çıkarılmasının başlıca sebebidir. Bu değişikliğe uyumlu altimetreler üretilmesi ile Avrupa Bölgesinde ki, Ülkemizde dahil olduğu Ülkelerde 24 Ocak 2002 tarihinde RVSM (Reduced Vertical Separation Minimum, azaltılmış dikey ayırma minimumu) uygulamasına başlanılmıştır. RVSM kısaca, RVSM hava sahası içerisinde, FL290 ile FL410 arasında RVSM onaylı uçaklar arasında 1000 feet'lik dikey ayırma uygulanmasıdır (Ertaş,S. 2004).

2.5 Uçak Performans Karakteristikleri

İdeal bir ticari uçakta aranan, satın alım ücretinin ve bakımın ekonomik olmasıdır. Ayrıca yolcu kapasitesi yüksek, yakıt tüketimi minimum olmalıdır. Bu karakteristiklerden hepsine aynı anda ve en iyi seviyede sahip olması mümkün olmaz fakat bu özelliklerin birçoğunu taşıyabilir. Uçağın dizaynındaki amaç, aracın performans kombinasyonu ile ekonomik cazibesi arasında bir oransal denge elde etmektir.

Uçuş rotasının herhangi bir noktasındaki uçuş irtifasında uçağın performansının belirlenmesi Uçak Yakıt Yanma Modeli (AFBM, Aircraft Fuel Burn Model) ile sağlanabilir. Bu model potansiyel ve kinetik enerjilerin farkının değişimindeki enerji dengesi konseptini kullanır. Enerji dengesinin denklemi aşağıdaki gibi yazılabilir:

$$E_T = \Pi E_D, \quad (2,13)$$

Burada itki enerjisi (E_T) ile oluşan sürtünme enerjisi (ΠE_D) eşitlenir. Enerji denge denklemi aşağıdaki hale gelir.

$$F_t = DC_D, \quad (2,14)$$

Burada itki (F_t), sürtünmenin (D) sürtünme katsayısı (C_D) ile çarpımına eşittir. Okuyan kişinin nokta ve yol performansının farkını görebilmesi gerektiğinden uçuş yol profil denklemlerinin belirlenmesi önemlidir. Aşağıda herbir denklemin birbiri ile fonksiyonel ilişkisi belirtilmiştir. Görüldüğü üzere enerji terimleri uçağın performansı ve yol profil değişkenleri ile ilişkin olabilir

$$\Delta KE = f(V_1, V_2, W_1, W_2),$$

$$\Delta PE = f(h_1, h_2, W_1, W_2),$$

$$E_D = f(\rho, V, S_w, C_D, X),$$

$$X = f(V, T),$$

Burada;

- Başlangıç ve bitiş gerçek hızlarındaki (TAS) artış V_1 ve V_2 ile gösterilmiştir. (ft/sec)
- Uçağın ağırlığındaki değişim W_1 ve W_2 ile gösterilmiştir. (lb)
- Başlangıç ve bitişteki irtifa değişimi h_1 ve h_2 ile gösterilmiştir. (feet)
- Atmosfer yoğunluğundaki değişim ρ gösterilmiştir. ($lb - sec^2 / ft$)
- Uçağın seyahat süresi T gösterilmiştir. (sec)
- Uçağın menzili X gösterilmiştir. (feet)

Önceki bağıntılarda tüm değişkenler, kanat alanı (S_w) ve sürtünme katsayısı (C_D) haricinde uçağın yol profiline bağımlı olduğu bilinmektedir. Kanat alanının (S_w) her bir uçak modeli için ayrı olduğu bilinir ama sürtünme katsayısının, kaldırma katsayısı (C_L) ile olan ilişkisi de kendine hastır. Bundan dolayı gerekli kaldırma için özel işlemsel şartlar altında kaldırma katsayısı elde edilmek zorundadır. Sonra sürtünme katsayısı belirlenebilir.

Dikey düzlemde uçağın hareketine karşılık gelen kinematik denklemler:

$$m \cdot V = T - D - W(\sin \gamma)$$

$$m \cdot V \gamma = L - W(\cos \gamma)$$

$$X = V(\cos \gamma)$$

$$h = V(\sin \gamma)$$

Burada

X : uçağın menziline,

h : uçağın irtifasını,

V : uçağın gerçek hızını,

T : uçağın itkisini,

D : uçağın sürtünmesini,

W : uçağın ağırlığını,

m : uçağın kütesini,

γ : uçağın uçuş açısını ifade etmektedir.

Burada, gerçek hava hızı (TAS) ve irtifa çok yavaş bir şekilde değiştiğinden dolayı onların herbirisi için zaman türevlerinin yaklaşık olarak sıfır olduğu farz edilmiştir. Bu varsayımlarla, yukarıdaki dört denklemde ki ifadeler; ağırlık, kaldırmaya ve itki, sürtünmeye eşittir denilerek sadeleştirilmiştir (Schilling, G. 1997).

2.6 Uçak Yakıt Tüketimi

Bir uçağın yakıt tüketimi aşağıdaki değişkenlerin bir fonksiyonudur:

1. Aerodinamik Karakteristikler

2. Motor Tipi

3. Uçuş Profili

Aerodinamik karakteristikler her uçağın kendi dizaynına bağlı olan bir değişkendir. Uçuş esnasındaki yakıt tüketiminin tahmini için göz önüne alınan iki büyük karakteristik kaldırma ve sürüklenme kuvvetleridir. Genellikle bir uçağın

kaldırma kuvveti kanat geometrisinin, sürtünme kuvveti ise tüm uçağın fonksiyonudur.

Motor, hava aracının yakıt tüketimi işleminin fiziksel olarak gerçekleştirildiği tek parçasıdır. Sivil hava taşımacılığında genelde kullanılan motor tipleri turboprop ve turbofan'dır.

Bir uçağın yakıt tüketimi, belirli irtifa ve hızlarda uygulanacak görev için gerekli olan itkinin ve yararlanacağımız uçak motorunun fonksiyonudur. Gerekli olan itki bir uçağın aerodinamik karakteristiklerinin bir fonksiyonudur. Bir uçağın aerodinamik karakteristikleri de irtifa, hız ve uçak konfigürasyonuna bağlıdır. Bu yüzden bir uçağın yakıt tüketimi uçak karakteristiklerine, motor tipine ve uçuş profiline bağlıdır denmektedir ve zaten uçuş profilinde planlanan görevin gerçekleştireceği hız ve yükseklikler tanımlanmaktadır (TEC Training Manual).

2.7 SIMMOD Yakıt Tüketim Modeli

Yakıt tüketimini değerlendiren, varolan yakıt yanma modeli Gelişmiş Yakıt Yanma Modeli(Advanced Fuel Burn Model – MOD 830725) olarak MITRE şirketinden Bela P. Collins tarafından geliştirilmiştir (Collins,B. 1982).

Bu özel yakıt yanışının değerlendirilmesi modeli, enerji denge fikrine temel oluşturmuştur. Bu fikir uçağın enerji performansını modelleyen bir çekirdek denklemin geliştirilmiş halidir. Denklem, kaldırmanın sürüklenmeyle ve itkinin yakıt akışı ile olan ilişkisi gösteren sabit değer kullanılarak belirlenen uçağa uygulanmaktadır. Çoklu olasılıksal değişken eğrisi uygun teknikleri, uçak özel sabitlerinin elde edilip performans verileri ile birleştirilmesinde kullanılmaktadır. Uçak performans limitleri, uçağın özel sabitlerinden faydalanan deneysel ilişkilerce kullanılmaktadırlar.

Varsayımlar ve Tanımlar:

Yakıt tüketim algoritması, uçağın uçuş profili dinamik girdileri ve uçak performansına dayalı olan önceden bulunmuş katsayıların birleşimi ile tasarlanmıştır. Hesaplama prosedürlerinin basite indirgenmesi için aşağıdaki varsayımlar yapıldı:

- Artışların üzerindeki ağırlık değişimleri yakıt yanış hesaplamalarını etkilemeyecektir.
- Uçuş yol açıları küçük değerlerdir:

$$\cos(\phi) \approx 1$$

- Hız ve irtifa değişimleri arasında doğru orantı bulunur.

- Enerji Denge Yaklaşımı
- Yakıt yanış denklemi, temel enerjinin korunumu prensiplerinden elde edilir.
Enerji denge denklemleri:

(enerji deęiřimi) = (giren enerji) - (enerji kaybı) veya

(potansiyel enerjideki deęiřim + kinetik enerjideki deęiřim) = (itki kuvvetinin yaptığı iř – sřrtünme kuvvetinin yaptığı iř)

burada,

İtki kuvvetinin yaptığı iř = itki kuvveti x vektörün menzili

Sřrtünme kuvvetinin yaptığı iř = sřrtünme kuvveti x vektörün menzili

Bundan dolayı, enerji denge denklemini ařaęıdaki gibi yazabilir:

(potansiyel enerjideki deęiřim + kinetik enerjideki deęiřim) = (itki kuvveti x vektörün menzili – sřrtünme kuvveti x vektörün menzili)

$$\Delta PE + \Delta KE = (F_t \times d) - (D \times d)$$

İtki (F_t)'in çözümünün açıklanması:

$$F_t = \frac{\Delta KE}{d} + \frac{\Delta PE}{d} + D \quad (2.15)$$

yerine,

$$\Delta KE = \frac{W(V_2^2 - V_1^2)}{2g} \text{ ve } \Delta PE = W(h_2 - h_1)$$

Hız boyunca menzili ařaęıdaki gibi ifade edebiliriz:

$$d = \bar{V}t$$

yani,

$$\bar{V} = \frac{(V_1 + V_2)}{2}$$

Sřrtünmenin Hesaplanması:

Temel uçak performansına göre bulunan irtifada aęırlığın kaldırma kuvvetine eřit olması gerekmektedir. Bundan dolayı uçaęın küçük uçuř yol açısı uygulandıęı farzedilmiřtir. Buna ek olarak, sřrtünme (C_D) ve kaldırma katsayıları (C_L) genellikle boyutsuz olarak belirtilerek, řu řekilde yazılmıřtır:

$$Lift = Weight = \frac{1}{2} \rho V^2 S_w C_L$$

C_L için çözüm:

$$C_L = \frac{W}{\frac{1}{2} \rho V^2 S_w} \quad (2.16)$$

Benzer olarak, sürtünmeyi aşağıdaki gibi yazabilir:

$$D = \frac{1}{2} \rho V^2 S_w C_D \quad (2.17)$$

yerine,

$$C_D = C_{D,o} + f(C_L, e, AR)$$

Burada,

e = Oswald'ın verimlilik faktörü

AR = Kanadın yüzey oranı

Yukarıdaki denklemi açarak, toplam sürtünme katsayısını aşağıdaki gibi görülür:

$$C_D = \sum C_{D_{p_{\min}}} + C_{D_i} + C_{D_r} + C_{D_i} + C_{D_{PC_L}} + C_{D_c} \quad (2.18)$$

yani:

$\sum C_{D_{p_{\min}}}$ = Hafif türbülanslı akış için hava aracı komponentlerinin her birinin minimum profil sürüklenmelerinin toplamı

C_{D_i} = Hava aracının ağırlık merkezi etrafında ayarlanması için gerekli sürüklenme

$C_{D_{int}}$ = Komponentlerin birbirine etkisi sonucunda oluşan sürüklenme

C_{D_r} = Yüzeydeki pürüzlülük, basamak yapı, boşluk ve önemli çıkıntılardan kaynaklanan sürüklenme

C_{D_i} = Taşımanın spanwise dağılımına mukabil gelen belirli kanat taşıma katsayısındaki kanat vorteks kaynaklı sürüklenme, ayrıca eliptik ve eliptik olmayan katkıların net etkisi

$C_{D_{PC_L}}$ = Kanat, gövde ve diğer komponentlerin önemli katkılarını içeren net hava aracının taşımaya bağlı profil sürüklenmesi

C_{D_c} = Sıkıştırılabilirlik sürüklenmesi, kritik altı sürüklenme, dalga sürüklenmesi ve şok kaynaklı ayrılma sürüklenmesi

İlk dört terim taşımadan bağımsız iken takip eden iki terim taşıma ve mach sayısından bağımsız değildir. Ayrıca son terim sürüklenme yükselmesini açıklar. Bu bilgiler ile birlikte, aşağıdaki fonksiyonlar mach sayısı ile değişen, doğrusal olmayan sürüklenme kutbundan meydana gelen boyutsuz sürüklenme katsayısını bulmak için kullanılır.

$$C_D = M_a + M_b C_L^2 + M_c C_L^4$$

burada M_a , M_b ve M_c mach sayısının fonsiyonlarıdır. M_a denklem “(2.18)”in ilk dört terimini, M_b 5 ve 6. terimini, M_c ise son terimi temsil eder. Bu üç M_i fonsiyonları şu şekilde tanımlanır,

$$M_a = C_1 + C_2\Gamma^2 + C_3\Gamma^4$$

$$M_b = C_4 + C_5\Gamma + C_6\Gamma^2 + C_7\Gamma^3 + C_8\Gamma^4$$

$$M_c = C_9 + C_{10}\Gamma + C_{11}\Gamma^2 + C_{12}\Gamma^3$$

Burada,

$$\Gamma = \frac{1+M}{1-M} \text{ ve } C_i \text{ sürüklenme sabitidir.}$$

Temel aerodinamiğe göre sürüklenme, kritik mach sayısına ulaşıldığında önemli bir şekilde artar. Bu yüzden bu tarz bir davranışı açıklamak için yüksek düzenleme terimleri kullanılır. Böylelikle denklem “(2.17)”de gösterilen sürüklenme fonsiyonu şu şekilde tekrar yazılabilir:

$$D = \frac{1}{2}\rho V^2 S_w (M_a + M_b C_L^2 + M_c C_L^4)$$

Buradaki M fonsiyonu daha önce açıklandığı gibidir.

Denklem “(2.15)”deki enerji denge denklemini şu hale dönüştür:

$$F_n = \frac{\Delta KE}{d} + \frac{\Delta PE}{d} + \frac{1}{2}\rho V^2 S_w (M_a + M_b C_L^2 + M_c C_L^4)$$

denklem “(2.16)” için yerine koyulursa:

$$F_n = \frac{\Delta KE}{d} + \frac{\Delta PE}{d} + \frac{1}{2}\rho V^2 S_w M_a + M_b \left(\frac{W}{\frac{1}{2}\rho V^2 S_w} \right)^2 + M_c \left(\frac{W}{\frac{1}{2}\rho V^2 S_w} \right)^4$$

(2.19)

Burada enerji denge denklemini akustik hız, irtifa ve ağırlık gibi hava aracı değişkenleri ve bazı özel sabitlerden oluşur.

Flap ve iniş takımlarının yer değiştirmesi gibi hava aracı konfigürasyon değişimleri sürüklenme polarını etkileyebilir. Bu değişimleri açıklamak için aşağıdaki denklem kullanılmalıdır:

$$R_1 = 1 + (CF)(CC_1) + (CC_2)(GF) + (CC_3)(FA)(GF) + (CC_4)(FA) \\ + (CC_5)(FA)^2 + (CC_6)(FA)^3$$

$$R_2 = 1 + (CF)(CC_7) + (CC_8)(GF) + (CC_9)(FA)(GF) + (CC_{10})(FA) \\ + (CC_{11})(FA)^2 + (CC_{12})(FA)^3$$

$$R_3 = 1 + (CF)(CC_{13}) + (CC_{14})(GF) + (CC_{15})(FA)(GF) + (CC_{16})(FA) \\ + (CC_{17})(FA)^2 + (CC_{18})(FA)^3$$

Son sürüklenme denklemi aşağıdaki gibi meydana gelir:

$$F_n = \frac{\Delta KE}{d} + \frac{\Delta PE}{d} + \frac{1}{2} \rho V^2 S_w M_a R_1 + R_2 M_b \left(\frac{W}{\frac{1}{2} \rho V^2 S_w} \right)^2 + R_3 M_c \left(\frac{W}{\frac{1}{2} \rho V^2 S_w} \right)^4 \quad (2.20)$$

Yakıt akışı ve dolayısı ile zamanla birlikte yakılan yakıtın hesaplanması istenildiğinden, itki yakıt akışına çevrilmelidir.

Bir hava aracının yakıt yanışı temel olarak; gövde sürüklenmesi, motora has yakıt tüketimi, uçulacak yolun uzaklığı, dikey uçuş yolu ve hava aracı ağırlığına bağlıdır. Motor geliştirilmesinde ana faktör itki esaslı yakıt tüketimini (TSFC, Thrust Specific Fuel Consumption) minimize etmektir. TSFC motorun verimliliğinin bir ölçüsüdür ve pound cinsinden saat başına tüketilen yakıt akışının, pound cinsinden motor itki kuvvetine bölümü şeklinde hesaplanmaktadır (lb/hr/lb). Bir uçağın yakıt tüketimi, üzerindeki motora özgü olarak değişir. Turbojet ve turbofan tipi gaz türbinli motorlarda yakıt akışı iki faktöre bağlıdır. Bunlar; irtifa ve hızdır.

Turbojet motoru tanımlamak için kurulan deneysel ilişki aşağıda gösterilmiştir.

$$\hat{\mu} = \eta_1 + \eta_2 F_n + \eta_3 \eta F_n^2 \quad (2.21)$$

Burada η fonksiyonları:

$$\eta_1 = k_1 + k_2 \bar{M} + k_3 \bar{h} + k_4 \bar{M}\bar{h} + k_5 \bar{h}^2 + k_6 \bar{M}\bar{h}^2$$

$$\eta_2 = [k_7 + k_8 \bar{M} + k_9 \bar{h} + k_{10} \bar{M}\bar{h} + k_{11} \bar{h}^2 + k_{12} \bar{M}\bar{h}^2] (N \times 10^4)^{-1}$$

$$\eta_3 = [k_{13} + k_{14} \bar{M} + k_{15} \bar{h} + k_{16} \bar{M}\bar{h} + k_{17} \bar{h}^2 + k_{18} \bar{M}\bar{h}^2] (N \times 10^4)^{-2}$$

Collins 1984'e göre, yukarıdaki ilişkiler bir motorun içinde var olan sistemlere doğrudan bir fiziksel bağ içermezler. Bu fonksiyonların seçilme sebebi onların davranışının gerçeğe benzer olmasıdır.

Şimdi gösterilen denklem “(2.20)”deki enerji balans denklemi, “(2.21)”deki denklemde yerlerine koyulabilir. Gelişmiş yakıt yanış modeli MOD830725 çekirdek denklemi aşağıda görüldüğü gibidir.

$$\begin{aligned}
\hat{\mu} = & \eta_1 + qS_w M_a R_1 + \frac{R_2 \eta_2 M_b W^2}{qS_w} + \frac{R_3 \eta_2 M_c W^4}{(qS_w)^3} + \frac{\eta_2 (V_2 - V_1) W}{gt} \\
& + \frac{(h_2 - h_1) W}{t\bar{V}} + \frac{\eta_3 W (V_2 - V_1)}{gt} + \frac{(h_2 - h_1) W^2}{t\bar{V}} + \frac{2(V_2 - V_1) W}{gt} + \frac{(h_2 - h_1) W}{t\bar{V}} \\
& + \eta_3 M_a qS_w R_1 + \frac{R_2 \eta_3 M_b W^2}{qS_w} + \frac{R_3 \eta_3 M_c W^4}{(qS_w)^3} + \eta_3 M_a^2 (qS_w)^2 R_1 \\
& + 2R_1 \eta_3 M_a M_b W^2 R_2 + \frac{2R_1 \eta_3 M_a M_c W^4 R_3}{(qS_w)^2} + \frac{R_2 \eta_3 M_b W^2}{qS_w} \\
& + \frac{R_3 \eta_3 M_c W^4}{(qS_w)^3} + \eta_3 M_a^2 (qS_w)^2 R_1 + 2R_1 \eta_3 M_a M_b W^2 R_2 \\
& + \frac{2R_1 \eta_3 M_a M_c W^4 R_3}{(qS_w)^2} + \frac{\eta_3 M_b^2 W^4 R_2^2}{(qS_w)^2} \\
& + \frac{2R_2 \eta_3 M_b M_c W^6 R_3}{(qS_w)^4} + \frac{\eta_3 M_c^2 W^8 R_3^2}{(qS_w)^6}
\end{aligned}$$

Çekirdek denklem tüm aerodinamik özellikleri ve çok kısa formdaki motor verilerini birleştirir. Bu modeli kullanmanın amacı; belirlenen bir uçak için herhangi bir uçuş yörünge üretim programına eklenebilir olmasıdır. Malesef, bu modelde katsayılar rüzgar tüneli testinden ve/veya test uçuşundan sağlanmak zorundadır. Bunun sebebi ise uçak aerodinamikleri ve motor özellikleri, düşük Mach sayısında ve yüksek Mach sayısında oldukça farklıdır. Kaldırma ve sürüklenme için teorik modeller genelde Mach sayısının yaklaşık 0,4'lük bir değerden daha az olduğu durumlarda havanın sıkıştırılmayan akışı ile sınırlıdır. Havanın özelliklerinin davranışını ve yüksek Mach sayılarındaki motorun davranışlarını tanımlama teşebbüsü karmaşık ve zor bir iştir. Farklı uçuş şartları altındaki taleplerde her bir uçak için test uçuşları ve rüzgar tüneli testindeki davranışlar tespit edilir ve gerekli katsayıların üzerindeki belirlenir ve sorgulanır. Bu yüzden bu model pratikten oldukça uzaktır.

2.8 Yapay Sinir Ağları Yardımıyla Yakıt Tüketimi

Uçakların yakıt tüketim oranlarının hesaplanması için yapay sinir ağları kullanımı daha önce Schilling tarafından 1997’de yapılmıştır. Schilling bu çalışmada yakıt yanışını hesaplamak için Collins’in modelinden faydalanmış ve sonra kullanılmış bu sonuçlarla yapay sinir ağlarının eğitilmesini desteklemiştir. Schilling, uçağın yakıt tüketim tahmini için bir yapay sinir ağ potansiyeli gösterdi. Bu araştırma projesinin ana fikri Schilling’in projesindeki yakıt tüketimi hesabında girdi verisi olarak kullandığı uçuş el kitabından alınan optimum değerler yerine herhangi bir uçuşun sonucunda kara kutudan alınan değerlerin kullanılması ile gerçekçi sonuçların elde edilmesidir.

Sivil havacılık endüstrisinde var olan bütün uçaklar uçuş sertifikasyon işlemi esnasında uçak üreticisi tarafından test edilir (FAR Parts 23,25 veya 27 gereği). Malesef, bu uçakların pek çoğunun test sonuçları gizlidir. Uçuş el kitabı, her bir uçak modeli için bilginin ortak kaynağıdır. Fakat kara kutuda ki parametreler bir uçuştan alınan gerçek değerlerdir.

2.9 Yapay Sinir Ağlarına Giriş

Gelişen teknolojinin yazılım ve donanım geliştirme ortamları üzerinde tasarımcıya sunmuş olduğu olanakların gün geçtikçe çeşitlilik kazanması karmaşık sistemleri ortaya çıkarmış ve bu, gerek çözümü aranan problemlerin matematiksel modelinin geliştirilmesini gerekse bu problemlere önerilen çözümlerde istenen hassasiyetin ve bozucu çevresel etkenlere karşı duyarsızlık özelliğinin kazanılmasını güçleştirmiştir.

Bilim dünyası 1940’lı yıllarda yapay sinir ağları ile tanıştı. Bu alanda yapılan ilk çalışmalar beyin hücrelerinin işlevlerinin ve birbirleri ile haberleşme şekillerinin ortaya çıkarılmasını amaçlamaktaydı. O zamandan beri yapay sinir ağları gerek teorik gerekse pratik anlamda dikkate değer miktarda yol kattetti. Bugün birçok hücrenin belli bir düzende bir araya getirilmesi ve uygun öğrenme algoritmaları ile sinir ağlarını kurabilmekte ve bu ağlar çok karmaşık görevleri başarıyla yerine getirebilmektedir. Robot denetiminden ses tanıma uygulamalarına kadar birçok alanda yapay sinir ağlarına rastlanabilir. Bu sistemleri bu kadar ilginç kılan özelliklerden bazıları sistemin, kendini oluşturan alt öğelerin hatalarını kompanze edebilmesi ve karışık eşleştirmeleri belli koşullar sağlandığı takdirde önceden tanımlanabilen bir hata sınırı içerisinde gerçekleyebilmesidir (Efe,Ö.&Kaynak,O. 2004).

Yapay sinir ağıları özellikle kompleks ve doğrusal olmayan çok değişkenli sistemler ile ilgili problemlerin incelenmesinde etkili özelliklere sahiptir. Doğrusal olmayan sistemlerin modellenmesinde ve parametre kestiriminde önemli bir yöntem olarak son yıllarda kullanımı gittikçe yaygınlaşmıştır (Aykan,R.&diğ. 2006).

2.9.1 Yapay Sinir Ağları Modelinin Temel Esasları

Yapay Sinir ağlarının karakteristik özellikleri uygulanan ağ modeline göre değişmektedir. Burada bütün modeller için geçerli olan genel karakteristik özellikler verilmiştir. Bunlar aşağıdaki gibi sıralanabilir:

Yapay sinir ağları makine öğrenmesi gerçekleştirirler: Yapay sinir ağlarının temel işlevi bilgisayarın öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar.

Programları çalışma stili bilinen programlama yöntemlerine benzemektedirler: Geleneksel progama ve yapay zeka uygulandığı bilgi işleme yöntemlerinden farklı bir bilgi işleme yöntemi vardır.

Bilginin saklanması: Yapay sinir ağlarında bilgi, ağın bağlantılarının değeri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlarda olduğu gibi veriler bir veri tabanında veya programın içinde gömülü değildir. Bilgiler ağın üzerinde saklı olup ortaya çıkması ve yorumlanması zordur.

Yapay sinir ağları örnekleri öğrenirler: Yapay sinir ağlarının olayları öğrenebilmesi için o olay ile ilgili örneklerin belirlenmesi gerekmektedir. Örnekleri kullanarak ilgili olay ile hakkında genelleme yapabilecek yeteneğe kavuşturulurlar (adaptif öğrenme). Örnek bulunmuyorsa ve yok ise yapay sinir ağının eğitilmesi mümkün değildir. Örnekler ise gerçekleşmiş olan olaylardır. Mesela bir doktor hastasına bazı sorular sorar ve aldığı cevaplara göre teşhis ederek ilaç yazar. Sorulan sorular ve verilen cevaplar konulan teşhis bir örnek olarak nitelendirilir. Bir doktorun belirli bir zaman içinde hastaları ile yaptığı incelemeler zaman içinde hastaları ile yaptığı görüşmeler örnek olarak alınırsa yapay sinir ağları benzer hastalıklara benzer teşhisler koyabilir. Elde edilen örnekleri olayın tamamen gösterebilmesi çok önemlidir. Ağa, olay bütün yönleriyle gösterilmez ve ilgili örnekler sunulmaz ise başarılı sonuç elde edilmez. Bu ağın sorunlu olduğundan değil olayın ağa gösterilmediğindedir. O nedenle örneklerin oluşması ve toplanması yapay sinir ağında önemli bir özelliğe sahiptir.

Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir: Yapay sinir ağlarının eğitilmesi

demek, mevcut örneklerin tek tek ağı gösterilmesi ve ağın kendi mekanizmalarını çalıştırarak örnekteki olaylar aransındaki ilişkileri belirlemesidir. Her ağı eğitmek için elde bulunan örnekler iki ayrı sete bölünürler. Birincisi ağı eğitmek için (eğitim seti) diğeri ise ağın performansını sınamak için (test seti) kullanılır. Her ağ önce eğitim seti ile eğitilir. Ağ bütün örneklerle doğru cevap vermeye başlayınca eğitim işi tamamlanmış kabul edilir. Daha sonra ağın hiç görmediği test setindeki örnekler ağı gösterilerek ağın verdiği cevaplara bakılır. Eğer ağ hiç görmediği örneklerle kabul edilebilir bir doğrulukta cevap veriyor ise o zaman ağın performansı iyi kabul edilebilir ve ağ kullanıma alınarak gerekirse çevrimiçi (on-line) kullanılır. Eğer ağın performansı yetersiz olursa o zaman yeniden eğitmek veya yeni örneklerle eğitmek gibi bir çözüme gidilir. Bu işlemler, ağın performansı kabul edilebilir bir düzeye gelinceye kadar devam eder.

Görülmemiş örnekler hakkında bilgi üretebilirler: Ağ kendisine gösterilen örneklerden genellemeler yaparak görmediği örnek hakkında bilgiler üretebilir.

Algılamaya yönelik olaylarda kullanılabilirler: Ağlar daha çok algılamaya yönelik bilgileri işlemede kullanılırlar. Bu konuda başarılı oldukları yapılan uygulamalarda görülmektedir. Bilgiye dayalı çözümlerde uzman sistemler kullanılmaktadır. Bazı durumlarda yapay sinir ağı ve uzman sistemleri birleştirmek daha başarılı sistemler oluşturmaya neden olmaktadır.

Şekil(örüntü) ilişkilendirme, sınıflandırma yapabilirler: Genel olarak ağların çoğunun amacı kendisine örnekler verilen örüntülerin kendisi veya diğerleriyle ilişkilendirilmesidir. Diğer bir amaç ise sınıflandırma yapmaktır. Verilen örneklerin kümelendirilmesi ve belirli sınıflara ayrıştırılarak daha sonra gelen bir örneğin hangi sınıfa gireceğine karar vermesi hedeflenmektedir.

Örüntü tamamlama gerçekleştirebilirler: Bazı durumlarda ağı eksik bilgileri içeren bir örüntü (pattern) veya bir şekil verilir. Ağın bu eksik bilgileri bulması istenir. Örneğin yırtık bir resmin kime ait olduğunu belirlemesi ve tam resmi vermesi gibi bir sorumluluk ağdan istenebilmektedir. Bu tür olaylarda yapay sinir ağlarının çok etkin çözümler ürettiği bilinmektedir.

Kendi kendini organize etme ve öğrenebilme yetenekleri vardır: Yapay sinir ağlarının örnekleri ile kendilerine gösterilen yeni durumlarda adapte olması ve sürekli yeni olayları öğrenebilmesi mümkündür.

Eksik bilgi ile çalışabilmektedirler: Yapay sinir ağları kendileri eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen

sonuç üretebilirler. Eksik bilgiler ile de çalışmaya devam ederler. Halbuki geleneksel sistemler bir eksik olunca çalışmazlar. Burada bir noktayı dikkatleri çekmekte fayda vardır. Yapay sinir ağlarının eksik bilgi ile çalışması performanslarını düşeceği anlamına gelmez. Performansının düşmesi eksik olan bilginin önemine bağlıdır. Hangi bilginin önemli olduğunu ağ kendisi eğitimi sırasında öğrenmektedir. Kullanıcıların bu konuda bir fikri yoktur. Ağın performansı düşük olunca kaybolan bilginin önemli olduğu kanaatine varılır. Eğer ağın performansı düşmez ise eksik olan bilginin önemli olmadığı anlaşılır.

Hata toleransına sahiptirler: Yapay sinir ağlarının eksik bilgilerle çalışabilme yetenekleri hatalara karşı toleranslı olmalarını sağlamaktadır. Ağın bazı hücrelerinin bozulması ve çalışmaz duruma düşmesi halinde ağ çalışmaya devam eder. Ağın bozuk olan hücrelerinin önemine göre performansında düşmeler görülebilir. Ağın bilgisinin yorumlanamamasının sebebi de budur.

Belirsiz tam olmayan bilgileri işleyebilmektedirler: Yapay sinir ağlarının belirsiz bilgileri işleyebilme yetenekleri vardır. Olayları öğrendikten sonra belirsizlikler altında ağlar öğrendikleri olaylar ile ilgili ilişkileri kurarak kararlar verebilirler.

Dereceli bozulma (Graceful degradation) gösterirler: Yapay sinir ağlarının hatalara karşı toleranslı olmaları bozulmalarının da dereceli (göreceli) olmasına neden olmaktadır. Bir ağ zaman içerisinde yavaş yavaş ve zarif bir şekilde bozulur. Bu eksik olan bilgidен veya hücrelerin bozulmasından kaynaklanır. Ağlar, herhangi bir problem ortaya çıktığında hemen anında bozulmazlar.

Dağıtık belleğe sahiptirler: Yapay sinir ağlarında bilgi ağı yayılmış durumdadır. Hücrelerin birbirleriyle bağlantılarının değerleri ağın bilgisini gösterir. Tek bir bağlantının bir anlamı yoktur. Daha önce belirtildiği gibi ağın bilgilerinin açıklanamamasının sebeplerinden birisi de budur. Bu ağlarda, ağın tamamı öğrendiği olayın bütünü karakterize etmektedir. O nedenle bilgiler ağı dağıtılmış durumdadır. Bu ise dağıtık bir belleğin doğmasına neden olmaktadır.

Sadece nümerik bilgiler ile çalışabilmektedirler: Yapay sinir ağları sadece nümerik bilgiler ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin nümerik gösterime çevrilmeleri gerekmektedir. Sembolik bilgilerin nümerik değerler ile ifade edilmesinde bilgilerin yorumlanmasını ve kararların (üretilen çözümlerin) açıklanmasını zorlaştırmaktadır.

Yukarıda belirtilen özelliklere ek olarak geliştirilmiş olan her modelin kendisine özgü özellikleri olabilmektedir. Burada açıklanan özellikler dikkatlice incelenirse

aslında yapay sinir ağlarının bilgisayar bilimine oldukça avantajlı katkılarının olduğu görülebilir. Geleneksel bilgisayar yazılım teknolojisi ile çözülemeyen birçok problemin yapay sinir ağları ile çözülebileceği görülebilir. Mesela yapay sinir ağları, eksik, normal olmayan, belirsiz bilgileri işleyebilen en güçlü problem çözme tekniğidir denilse yanlış olmaz. Belirsiz bilgileri işlemede bulanık önermeler mantığı (fuzzy logic) gibi teknikler olsa bile eksik bilgi ile çalışabilen teknikler bulmak çok zordur (Öztemel,E 2006).

2.9.2 Ağ Mimarisi

Yapay sinir ağları düğüm veya sinir olarak adlandırılan çok sayıdaki işlem elamanının bir araya gelmesiyle oluşur. Psikolog Frank Rosentblatt'ın öğrenme yeteneğine sahip olan bir örnek tanıma aygıtını ortaya çıkarmış olduğu 1958 yılından bu yana, hiyerarşik sinir ağı en çok üzerinde çalışılmış olan bir ağ yapısı olmuştur. Bir hiyerarşik sinir ağı, düğümlerin sıralı bir şekilde art arda bağlanmasından oluşur. Bu tür ağların özelliği sahip oldukları basit dinamikleridir. Eğer giriş katmanına bir işaret girerse, bu işaret sinirler arasındaki bağlantılar yoluyla diğer katmana iletilmeden önce bu işaret üzerinde basit bir işlem yerine getirilir. Bu süreç çıkış katmanına erişinceye kadar tekrar edilir.

Yapay sinir ağlarının düğümleri ve bağlantıları çok değişik biçimlerde bir araya getirilebilir. Ağlar bu düğüm ve bağlantı mimarilerine göre değişik isimler alırlar.

Yapay sinir ağ mimarileri, sinirler arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre birbirlerinden ayrılmaktadır. Buna göre yapay sinir ağları için, ileri beslemeli (feedforward) ve geri beslemeli (feedback veya recurrent) ağlar olmak üzere iki temel mimarisi vardır.

Ağ içerisindeki düğümler katmanlar halinde yerleştirilir. İlk katmandaki giriş verilen bilgi ağ içinde ileriye doğru yayılır. Her katmandaki düğümlere sadece önceki katmandaki düğümlerden giriş izni verilir. Bir düğüm kendinden sonraki herhangi bir düğüme bağlanabilirken kendisine asla bağlanmaz. Son katmandaki işaretler ağın çıkışıdır. Geri beslemeli veya tekrarlanan ağlarda en azından bir düğümün geriye yayıldığı bir dönüş bağlantısı vardır. Tekrarlanan ağlar da tamamen veya parçalı olarak geri besleme yollarına sahiptirler. Bu tür ağların tasarımları ve davranışları oldukça karmaşıktır.

Sinir ağlarında istenen sonucun elde edilmesi için ağın uyarlanabilir olması gerekir. Bunu sağlamak için uygun değerlikli ağırlıklar ve doğru bağlantılar seçilmelidir. Ağ bu şartları karşılayabilmek için sistemin davranışlarını öğrenmeli ya

da kendi kendini örgütlemelidir. Öğrenme kalıcı yenilenmeler için gözlemlene veya eğitim faaliyetlerinden çıkan sonuçlar olarak tanımlanabilir. Öğrenme yapay sinir ağının ayrılmaz bir parçasıdır. Öğrenme; giriş değerlerine veya bu girişlerin çıkışlarına bağlı olarak ağın bağlantı ağırlıklarını değiştiren veya ayarlayan öğrenme kuralı ile gerçekleştirilir.

Ağların eğitimi için kullanılan öğrenme kuralları genellikle danışmalı öğrenme (supervised learning), danışmansız öğrenme (unsupervised learning) ve pekiştirerek öğrenme (reinforcement learning) olmak üzere üç öğrenme yöntemi başlığı altında toplanabilir.

Danışmalı öğrenme kuralları, arzu edilen ağ çıkışının elde edilmesi için, çıkış hatasının düşürülmesinde ağırlıkların uygulanabilir hala getirilmesini gerektirir. Danışmalı öğrenmede her giriş değerine istenilen çıkış sisteme tanıtılır ve yapay sinir ağının giriş çıkış ilişkisini gerçekleştirine kadar aşama aşama ayarlanır. Danışmalı öğrenmeye; çok katmanlı perceptron (multilayer perceptron), geriye yayılım (backpropagation), delta kuralı Witrow-Hoff veya en küçük karelerin ortalamaları (least mean square) ve uyarlanabilir doğrusal elaman anlamına gelen ADALINE örnek olarak verilebilir.

Danışmansız öğrenmede bir danışman veya öğretmen sinir ağına girişe hangi veri parçası sınıfına ait olduğunu veya ağın nerede iyi sonuç verdiği söylenmez. Ağ veriyi üyeleri birbirinin benzeri olan öbeklere yol göstermeksizin ayırır. Danışmansız öğrenme danışmanlı öğrenmeye göre çok daha hızlıdır. Ayrıca matematik algoritmaları da daha basittir. Danışmansız öğrenmeye, yarışmacı öğrenme (competitive learning), Kohonen'in özörgütlenmesi, harita ağları (self organizing), Hebbian öğrenme, Grossberg öğrenme gibi öğrenme kuralları örnek olarak verilebilir.

Yaparak öğrenme veya pekiştirerek öğrenme yönteminde ağ doğrudan gerçek ağ çıkışını vermez; ağ çıkışın iyi yada kötü olarak değerlendirilmesini yapar. Performans bilgisi genellikle ikili sayıdır ve denetim hareketleri sıranın başarısını gösterir (Elmas,Ç. 2003).

2.9.3 Sinirler


Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. En temel sinir modeli şekil 2.5'de görülmektedir. Yapay sinir ağı hücresinde temel olarak dış ortamdan ya da diğer sinirlerden alınan veriler yani girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar

bulunmaktadır. Dış ortamdan alınan veri, ağırlıklar aracılığıyla sinire bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Toplam fonksiyonu ise net girişi hesaplar, net giriş, girişler ve bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur (Elmas,Ç. 2003).

2.9.4 Katmanlar

Temel olarak tüm yapay sinir ağlarının basit topolojik yapıları vardır. Sinirlerin bir kısmı gerçek dünyadan girişlerini sağlarken, diğer sinirler ise ağıın çıkışlarında gerçek dünyayı oluşturur. Kalan sinirlerin tümü gerçek anlamda görünmediğinden gizli katman olarak adlandırılır.

Şekil 2.4: Çok Katmanlı Yapay Sinir Ağı



Şekil 2.4'de görüldüğü gibi sinirler katmanlarda öbeklenmiştir. Giriş katmanı dış çevreden giriş alan sinirleri içerir. Çıkış katmanı, sistemin çıkışı ile kullanıcı veya dış çevreye ileten sinirleri içerir. Genelde bu iki katman arasında birkaç gizli katman vardır.

Giriş katmanına bir giriş geldiğinde, sinirleri diğer katmanlara giriş olacak şekilde çıkış üretir. Bu işlem koşulları yerine getiren kesin durum oluşuncaya kadar veya çıkış katı çağrılıncaya kadar devam eder ve çıkışı dış çevreye aktarır.

Gizli sinirlerin (düğümlerin) sayısı ağıın en iyi şekilde çalışabileceği bir sayıda seçilmelidir. Eğer gizli sinir sayısı çok arttırılırsa, sonuç değerinin üzerine çıkmış olur. Bu durumda ağda genelleşme sorunu ortaya çıkacaktır (Elmas,Ç. 2003).

2.9.5 Katmanlar Arası Bağlantılar

Katmanlar arasında kullanılan değişik türde bağlantılar vardır. Katmanlar arasındaki bu bağlantılar katmanlar arası bağlantı olarak adlandırılırlar. Bu bağlantı çeşitleri aşağıda kısaca anlatılmıştır.

Tam bağlantılı: İlk katmandaki her sinir ikinci katmandaki her sinire bağlıdır.

Kısmi bağlantılı: İlk katmanın bir siniri, ikinci katmandaki her sinirle bağlantılı değildir.

İleri besleme: İlk katmandaki sinirlerin çıkışlarını ikinci kat sinirlerine gönderir, fakat ikinci kat sinirlerinden geri bir giriş almazlar.

Çift yönlü: İkinci katman sinirlerinin çıkışlarını birinci katman sinirlerine taşıyan bir başka bağlantı kümesi vardır.

İleri besleme veya çift yönlü bağlantılar tam veya kısmi bağlantı olabilir.

Hiyerarşik: Eğer sinir ağı hiyerarşik yapıya sahipse, düşük katmanların sinirleri bir sonraki seviyedeki katmanın sinirlerine iletilebilir.

Rezonans: Çift yönlü bağlantılı katmanlar, kesin durum oluşuncaya kadar defalarca mesajı bağlantı üzerinden göndermeye devam eder (Elmas,Ç. 2003).

2.9.6 Sinirler Arası Bağlantılar

Daha karışık yapılarda sinirler, katman içinde kendi aralarında haberleşirler.

Tekrarlamalı: bir katmanın içindeki sinirler tam veya kısmi olarak biri diğerlerine bağlı olabilir. Bu sinirler başka bir katmandan giriş aldıklarında, çıkışlar başka bir katmana göndermeden önce birinin çıkışı diğerine defalarca aktarılır. Genelde çıkışlarını diğer katmana iletmeden önce bazı durumlarda katmanın sinirleri arasında bağlantılar meydana gelir.

Merkezde/Çevre Dışı (On-center/Off surround): Bir katmandaki sinirin kendisi ve o anki komşuları için uyarım bağlantıları varken, diğer sinirler için yasaklayıcı bağlantıları vardır. Bu tür bağlantıları sinirlere rakip bir ekip olarak düşünebiliriz. Her ekip kendini ve ekip elemanlarını uyarır ve diğer ekiplerin tüm elemanlarını yasaklar. Birkaç işaret değişiminden sonra, etkin çıkış değerli sinirler kazanır. Bu durumda ya kendinin ya da ekip elemanlarının boyutlarının güncellemesine izin verilir. İki sinir arasında uyarıcı ve yasaklayıcı iki tür bağlantı vardır. Uyarıcı bağlantıda bir sinirin çıkışı bağlı bulunduğu sinirin faaliyet potansiyelini artırır. İki sinir arasında yasaklayıcı bağ var ise mesaj gönderen sinirin çıkışı alıcı sinirin faaliyet potansiyelini azaltır. Biri sonraki sinirin sayıcı mekanizmasında toplama işlemine neden olurken, diğeri çıkarma işlemine neden olur yani biri uyurken diğeri yasaktır (Elmas,Ç. 2003).

2.9.7 Ağırlıklar

Ağırlıklar bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Ağırlıkların büyük ya da küçük olması önemli veya önemsiz olduğu anlamına gelmez. Bir ağırlığın değerinin sıfır olması önemli veya önemsiz olduğu anlamına gelmez. Bir ağırlığın değerinin sıfır olması o ağ için en önemli olay olabilir. Eksi değerler önemsiz demek değildir. O nedenle artı veya eksi olması etkisinin pozitif veya negatif olduğunu gösterir. Sıfır olması ise herhangi bir etki olmadığını gösterir. Ağırlıklar değişken veya sabit değerler olabilirler (Öztemel,E. 2006).

2.9.8 Hatırlama (Recall)

Sinir ağının öğrenme fazında sahip olunan bilgileri uyguladığı faza “hatırlama fazı” denir. Hatırlama her zaman bir giriş paterninin, sinir ağının giriş katmanına uygulanması ile başlar. Giriş sinirlerinin herbiri giriş paterninin özel bir komponentini tutar ve normalde işlemez fakat basitçe bağlantılı sinirlere iletir. Halbuki çıkışlar, takip eden sinire ulaşmadan önce bu çıkış bağlantısındaki ağırlık ve bias tarafından modifiye edilir.

İkinci katmanın bütün sinirleri bundan sonra modifiye edilmiş ağırlık&bias değerleri alır ve işler. Daha sonra bu sinirlerde, bir sonraki katmanın takip eden sinirlerine gönderir. Bu prosedür sinir ağının giriş paternine cevabı olan çıkışın, son katmanın sinirleri tarafından üretilmesine kadar tekrarlanır (Trani,A. 2004).

2.9.9 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonu işlem süresince net çıkışını hesaplar ve bu işlem aynı zamanda sinirin çıkışına verir. Genelde aktivasyon fonksiyonu doğrusal olmayan (nonlinear) bir fonksiyondur. Şekil 2.5’de görülen b bir sabittir, bias veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılır. Yapay sinir hücresinin matematiksel modeli şöyledir.

Çıkış,

$$O = f(W \cdot X + b)$$

şeklinde sinir çıkışı hesaplanır. Buradaki W ağırlıklar matrisi, X ise girişler matrisidir. n giriş sayısı olmak üzere;

$$W = w_1, w_2, w_3, \dots, w_n$$

$$X = x_1, x_2, x_3, \dots, x_n$$


şeklinde yazılabilir. Formülize edersek;

$$net = \sum_{i=1}^n w_i x_i + b \quad \text{ve} \quad O = f(net)$$

$$O = f\left(\sum_{i=1}^n w_i x_i + b\right) \text{ şeklinde de yazılabilir.}$$


Yukarıdaki formülde görülen “ f ” aktivasyon fonksiyonudur. Genelde nonlinear olan aktivasyon fonksiyonunun çeşitli tipleri vardır.

Şekil 2.5: Temel Yapay Sinir Ağı Hücresi




Aşağıdaki şekilde eşik aktivasyon fonksiyonunun grafiği görülmektedir. Eşik aktivasyon fonksiyonu eğer net değeri sıfırdan küçükse sıfır, sıfırdan daha büyük bir değer ise net çıkışında +1 değeri verir. Eşik aktivasyon fonksiyonunun -1 ile $+1$ arasında değişeni ise signum aktivasyon fonksiyonu olarak adlandırılır. Signum aktivasyon fonksiyonu, net giriş değeri sıfırdan büyükse $+1$, sıfırdan küçükse -1 , sıfıra eşitse sıfır değerini verir.

Şekil 2.6: Eşik Aktivasyon Fonksiyonu.



Aşağıdaki şekilde doğrusal aktivasyon fonksiyonu görülmektedir. Doğrusal aktivasyon fonksiyonunun çıkışı girişine eşittir. Sürekli çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonunun doğrusal aktivasyon fonksiyonu olabildiğine dikkat edilmelidir.


Şekil 2.7: Doğrusal Aktivasyon Fonksiyonu



$f(x) = x$ şeklinde ifade edilir.

Aşağıdaki şekilde logaritma sigmoid transfer fonksiyonu görülmektedir. Lojistik fonksiyon olarak da adlandırılmaktadır. Bu fonksiyonunun lineer olmamasından dolayı türevi alınabilmektedir. Böylece daha sonraki bölümlerde görülecek olan geri yayınlımlı ağlarda kullanmak mümkün olabilmektedir.

Şekil 2.8: Logaritma Sigmoid Aktivasyon Fonksiyonu



Lojistik fonksiyonu,

$$f(x) = \text{lojistik}(x) = \frac{1}{1 + \exp(-\beta x)}$$

şeklinde ifade edilir. Buradaki β eğim sabiti olup genelde bir olarak seçilmektedir. Diğer bir aktivasyon fonksiyonu olan hiperbolik tanjant aktivasyon fonksiyonu da lineer olmayan türevi alınabilir bir fonksiyondur. +1 ile -1 arasında çıkış değerleri üreten bu fonksiyon lojistik fonksiyona benzemektedir. Denklemi aşağıda görüldüğü gibidir.

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Bu aktivasyon fonksiyonlarından başka fonksiyonlar da vardır. Yapay sinir ağında hangi aktivasyon fonksiyonunun kullanılacağı probleme bağlı olarak değişmektedir. Yukarıda verilen fonksiyonlar en genel aktivasyon fonksiyonlarıdır.

2.9.10 Öğrenme ve Test Etme

Yapay sinir ağlarında proses elemanların bağlantılarının ağırlık değerlerinin belirlenmesi işlemine “ağın eğitilmesi” denir. Başlangıçta bu ağırlık değerleri rasgele olarak atanır. Yapay sinir ağları kendilerine gösterildikçe bu ağırlık değerleri değiştirirler. Amaç ağa gösterilen örnekler için doğru çıktıları üretecek ağırlık değerlerini bulmaktır. Örnekler ağa defalarca gösterilerek en doğru ağırlık değerleri bulunmaya çalışılır. Ağın doğru ağırlık değerlerine ulaşması örneklerin temsil ettiği olay hakkında genellemeler yapabilme yeteneğine kavuşması demektir. Bu genelleştirme özelliğine kavuşması işlemine ağın “öğrenmesi” denir. Ağırlıkların değerlerinin değişmesi belirli kurallara göre yürütülmektedir. Bu kurallara “öğrenme kuralları” denir. Daha önce belirtildiği gibi, kullanılan öğrenme stratejisine göre değişik öğrenme kuralları geliştirilmiştir.

Yapay sinir ağlarında öğrenme olaylarının iki aşaması vardır. Birinci aşamada ağa gösterilen örnek ile ağın üreteceği çıktı belirlenir. Bu çıktı değerinin doğruluk derecesine göre ikinci aşamada ağın bağlantılarının sahip olduğu ağırlıklar değiştirilir. Ağın çıktısının belirlenmesi ve ağırlıkların değiştirilmesi öğrenme kuralına bağlı olarak farklı şekillerde olmaktadır.


Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini (performansını) ölçmek için yapılan denemelere “ağın test edilmesi” denmektedir. Test etmek için ağın öğrenme sırasında görmediği örnekler kullanılır. Test etme sırasında ağın ağırlık değerleri değiştirilmez. Test örnekleri ağa gösterilir. Ağ eğitim sırasında belirlenen bağlantı ağırlıklarını kullanarak görmediği bu örnekler için çıktılar üretir. Elde edilen çıktılarının doğruluk değerleri ağın öğrenmesi hakkında bilgiler verir. Sonuçlar ne kadar iyi olursa eğitimin performansı da o kadar iyi demektir. Eğitimde kullanılan örnek setine “eğitim seti”, test etmek için kullanılan sete ise “test seti” adı verilmektedir. Yapay sinir ağlarının bu şekilde bilinen örneklerden belirli bilgileri çıkartarak bilinmeyen örnekler hakkında yorumlar (genelleme) yapabilme yeteneğine “adaptif öğrenme” denir (Öztemel,E. 2006).

2.9.11 Yapay Sinir Ağı Tipleri

En basit ve en genel yapay sinir ağları tek yönlü sinyal akışını kullanırlar. Yapay sinir ağı modelleri temel olarak iki grupta toplanmaktadır. İleri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları. İleri beslemeli yapay sinir ağlarında gecikmeler yoktur, işlem girişlerden çıkışlara doğru ilerler. Çıkış değerleri

öğreticiden alınan istenen çıkış değeriyle karşılaştırılarak bir hata sinyali elde edilerek ağ ağırlıkları güncellenir.

Şekil 2.9: İleri Beslemeli Yapı



Geri beslemeli yapay sinir ağlarında ise tıpkı kontrol uygulamalarında olduğu gibi gecikmeler söz konusudur. Geri beslemeli sinir ağı, çıkışlar girişlere bağlanarak ileri beslemeli bir ağdan elde edilir. Ağın t anındaki çıkışı $O(t)$ ise, $t + \Delta$ anındaki çıkışı ise $O(t+\Delta)$ 'dir. Buradaki Δ sabiti sembolik anlamda gecikme süresidir. İleri beslemeli yapay sinir ağları notasyonu kullanılarak $O=(t+\Delta)$ şöyle yazılabilir:

$$O(t + \Delta) = f[W \cdot o(t)]$$

Dikkat edilmesi gereken nokta başlangıç anında $x(t)$ 'ye ihtiyaç duyulmasıdır. Başlangıç anında $O(0) = X(0)$ 'dir.

2.9.12 Geri Yayınım Modeli

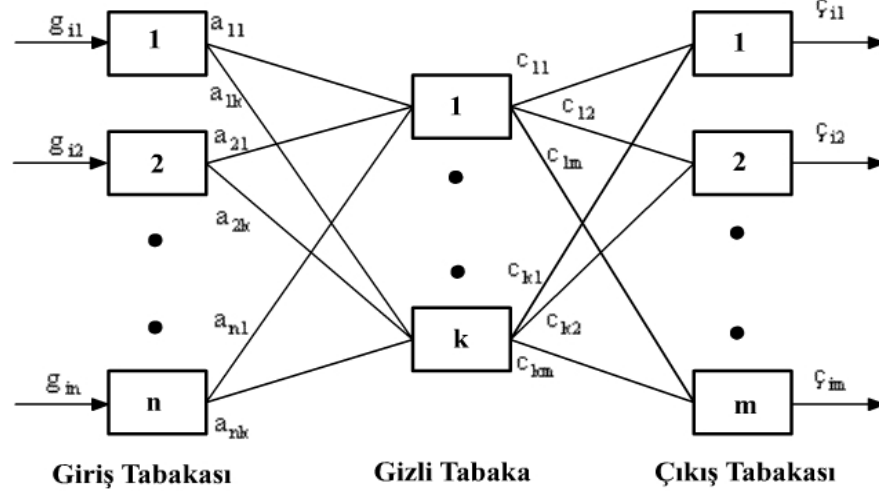
Minsky ve Papert (1969) iki tabakalı ileri beslemeli ağların tek tabakalı algılayıcıya göre birçok sınırlandırmayı ortadan kaldırdığını göstermiş fakat tabakalar arasındaki bağlantı ağırlıklarının nasıl değişebileceğine dair bir çözüm önerememiştir. Yapay sinir ağlarının eğitilmesi ile ortaya çıkan bu soruna bir çözüm bulunamadığından uzun yıllar yapılan çalışmalarda bir ilerleme sağlanamamıştır. Bu yüzden bir durgunluk dönemine giren yapay sinir ağları bu sessizliği 1980'li yıllara kadar sürdürmüştür.

Rumelhart ve ark. (1986) tarafından ortaya atılan geriye yayılma (yayınım) algoritması yapay sinir ağlarına olan ilginin yeniden canlanmasını sağlamıştır. Çünkü ortaya atılan algoritma örgün bir yöntem olmakla birlikte karmaşık bir matematik esasa dayanmaktadır. Ayrıca bu algoritma daha önceleri fazla bir başarı sağlanamayan giriş-çıkış tasvirleri, sınıflandırma ve genelleme gibi birçok problemin daha iyi çözülebilmesini sağlamıştır. Böylece yapay sinir ağlarında bir dönüm noktası olarak kabul edilen geriye yayılma algoritması birçok problemin çözülmesini mümkün kılmış ve çok sayıdaki başarılı uygulamaların yapılmasına imkan sağlamıştır.

Geriyeye yayılma algoritması gizli tabaka içeren yapay sinir ağlarında kullanılan güçlü bir öğrenme algoritmasıdır. Bunun esası alt sistemlerde meydana gelen bir yapay sinir ağındaki değişimlerin tamamen ve etkili bir şekilde hesaplanabilmesine dayanmaktadır. Bu da yapay sinir ağlarının karmaşık doğrusal olmayan ve işlem parametreleri arasındaki ilişkinin öğrenilmesini ve kullanılmasını mümkün kılmaktadır (VERBOS,P. 1994).

Geriyeye yayılma algoritmasında iki temel akış vardır. Bunlardan birincisi ağlar üzerinden ileri doğru olan bilgi akışı, ikincisi ise geriyeye doğru olan hatanın yayılmasıdır. İleri doğru akışta bağlantı katsayıları kullanılarak girişlere karşı çıkışlar elde edilir. Geriyeye doğru olan akışta ise gerçek çıkışlar ile hesaplanan çıkış değerleri yardımıyla elde edilen hatanın geriyeye doğru yayılarak ağırlıkların değiştirilmesi sağlanır.

Şekil 2.10: Genel Bir Yapay Sinir Ağları Mimarisi



Tüm öğrenme usullerinde olduğu gibi geriyeye yayılma algoritmasındaki amaç da giriş ve çıkış verileri arasındaki en uygun tasviri sağlayacak olan bağlantı ağırlıklarının elde edilmesidir. Şekil 2.10'daki gibi bir topolojiye sahip olan ağ üzerindeki geriyeye yayılma algoritması adım adım şu şekilde gerçekleşir.

- 1) Öncelikle YSA'nın topolojik yapısının belirlenmesi için katman ve herbir katmandaki hücre sayısı tespit edilir.
- 2) Yukarıdaki ifadelerde bulunan sabit parametrelerin değerleri atanır.
- 3) Tabakalar arasındaki ağırlık bağlantıları olan a ve c değerleri rastgele bir şekilde atanır.

- 4) n ölçüm sayısı olmak üzere atanan bağlantı ağırlıkları kullanılarak her bir giriş vektörü c_{kj} ($i=1, \dots, n; j=1, \dots, m$) çıktıları elde edilir.
- 5) Hataların yayılma işlemine çıkış katmanı ile gizli tabaka arasındaki bağlantı ağırlıklarından başlanarak önce a_{ij} değerleri,

$$a_{ij}^{yeni} = a_{ij}^{eski} - \eta \frac{\partial E}{\partial a_{ij}} \quad (2.22)$$

şeklinde yenilenir.

- 6) Burada η öğrenme oranı olmak üzere sıfırdan farklı sayısal bir değerdir. Ağırlık katsayıları olan a_{ij} değerlerinin yenilenebilmesi öncelikle hata değeri ve hata değerinin a_{ij} bağlantı ağırlıklarına göre türevlerinin hesaplanması gerekir.
- 7) Yapay sinir ağlarının vermiş olduğu çıkış değerleri olan ζ_{kj} ve c_{kj} değerleri, beklenen b_{ij} kullanılarak toplam hata değeri şu şekilde hesaplanır.

$$H_T = \sum_{i=1}^n \sum_{j=1}^m (\zeta_{ij} - b_{ij})^2 \quad (2.23)$$

- 8) Her bir ağırlık katsayısının yenilenebilmesi için H_T 'nin bağlantı ağırlıklarına göre teker teker türevinin alınması ile,

$$\frac{\partial H_T}{\partial a_{ij}} = \frac{\partial}{\partial a_{ij}} \left[\sum_{i=1}^n \sum_{j=1}^m (\zeta_{ij} - b_{ij})^2 \right] \Rightarrow \frac{\partial H_T}{\partial a_{ij}} = 2 \sum_{k=1}^n (\zeta_{kj} - b_{ij})(-1) f'(b_{ij}) y_i \quad (2.24)$$

elde edilir. İşlemci olarak sigmoid fonksiyonu kullanıldığından bunun türevi

$$f'(b_{ij}) = b_{ij}(1 - b_{ij}) \quad (2.25)$$

olarak ifade edilir. Böylece tüm işlemler tamamlandıktan sonra a_{ij} bağlantı ağırlıklarının yenilenmesi sağlanmış olur.

- 9) Hatanın a_{ij} bağlantı ağırlıkları üzerine yayıldığı gibi aynı şekilde c_{ij} üzerine de yayılması gerekir. Bu sebeple c_{ij} bağlantı ağırlıklarının yenilenmesi Denklem 2.22'ye benzer olarak,

$$v_{ij}^{yeni} = v_{ij}^{eski} - \eta \frac{\partial H}{\partial c_{ij}} \quad (2.26)$$

ile gerçekleştirilir.

10) Zincir kuralı yardımıyla H_T teriminin c_{ij} ağırlıklarına göre olan değişimi aşağıda gösterilmiştir.

$$\frac{\partial H_T}{\partial c_{ij}} = \frac{\partial H_T}{\partial b_{ij}} \frac{\partial b_{ij}}{\partial g_{ij}} \frac{\partial g_{ij}}{\partial c_{ij}} \Rightarrow \frac{\partial H_T}{\partial c_{ij}} = 2 \sum_{i=1}^n \sum_{j=1}^q (c_{ij} - b_{ij})(-1) f'(b_{ij}) a_{ji} f'(g_{ji}) a_{ij} \quad (2.27)$$

Böylece A ve C bağlantılı değerleri tamamen yenilediğinden dolayı başta atanmış olan rasgele değerlerden farklı değerlere sahip olacağından sonuçta yapay sinir ağlarının bir kez eğitilmesi tamamlanmıştır. Dikkat edilecek olursa herbir eğitim sonucunda hata daima geriye yayıldığından hata değeri azalacaktır. Hata değerinin her eğitim sonuçlarında azalması giriş ile çıkış verileri arasındaki tasviri gerçekleştirecek uygun ağırlık katsayılarına yaklaştığını göstermektedir.

Ağın eğitilmesinin sağlıklı bir şekilde gerçekleştirmesi için başlangıçta rasgele olarak atanan bağlantı ağırlıkları çok önemlidir. Rasgele olarak atanan bağlantı ağırlıkları eğitime hangi noktadan başlayacağımızı belirlemektedir. Başlanan bu noktanın gerçek çözüme çok yakın veya uzak bir nokta olması tamamen başta belirleyeceğimiz değerlere bağlıdır. Alexander ve Norton (1992) eğitime işlemine ağırlıklara eşit değerler atanmasıyla başlanması durumunda eğitime işleminin gerçekleşmeyeceğini belirtmektedir. Bunu sebebi aynı hata değerinin aynı değere sahip bağlantı ağırlıklarına doğru yayıldığında bağlantı ağırlıklarının birbirinden farklı değerler almayacak olmasını göstermektedir.

Yapay sinir ağlarında önemli noktalardan biri de eğitimin ne kadar sürdürüleceğine karar verilmesidir. Eğitime işleminin tamamlanması için iki seçenek mevcuttur. Bunlardan birincisi belli miktardaki hata toleransını göze almaktır. O hata değerinden daha düşük hata değerinde ulaşıncaya kadar eğitmeyi sürdürmektir. Dolayısıyla bu durumda eğitime sayısından ziyade hata miktarı önemlidir. Burada hata toleransının makul sınırlar içerisinde olması gerekmektedir. Aksi takdirde eğitime sayısı ne kadar artırılırsa artırılın istenilenden daha düşük hata değerlerine ulaşılması güçleşecektir. Diğer seçenek sabit bir eğitim sayısının seçilmesidir. Burada eğitici belirlenen eğitime sayısı sonucunda elde edilecek olan hatayı kabul etmektedir. Eğitici yapılacak olan çalışmaya göre baştan eğitmenin nasıl gerçekleştirileceğine karar verir.

Bütün bunlardan sonra “(2.22)” ve “(2.26)” denklemlerine bakıldığında denklemlerin sağ tarafından hatanın bağlantı ağırlıklarına göre türevi görülür. Her bir eğitim sonunda hata değeri azalacağından bu türevler gittikçe azalacak ve ideal bir durum için sıfır değerine ulaşması beklenecektir. Bu durumda eğitime işlemi ne kadar

sürdürülürse sürdürülsün a_{ij} ve c_{ij} değerlerinde herhangi bir değişiklik olmayacak yani bağlantı değerleri durağan hale gelecektir. Bu gibi ideal durumlar için eğitimin durdurulma safhası hata teriminin sifıra ulaştığı noktadır. Ancak hata teriminin sifıra ulaşması pratikte özel durumlar hariç pek mümkün değildir. Çünkü özellikle belirsizliğinde etkili olduğu doğal olaylarda giriş ve çıkış değişkenleri arasında sifır hata ile tasvir yapılabilmesi mümkün değildir. Gerçekte hata yüzeyi genellikle hem yerel noktalara hem de genel en küçük noktasına sahip bir yüzeydir. Yapay sinir ağlarının eğitilmesindeki amaç bu yüzey üzerindeki genel minimum noktasına ulaşabilmektir.

Eğitim esnasında hata değerinin daima azalması beklenmemelidir. Bazen hatanın arttığı da gözlenebilir. Bu genellikle çözümden uzaklaştığımızın belirtisidir. Hata yüzeyi üzerinde yerel bir en küçük noktaya ulaşılmış iken eğitime devam edilirse, yerel en küçükten kurtuluncaya kadar hata değeri belli bir miktar artar. Daha sonra diğer bir en küçüğe doğru ilerlediğinde hata değeri yeniden azalmaya başlar. Bununla birlikte hata değerinin hiç azalmadan artması da o noktanın genel bir en küçük nokta olduğunun göstergesidir. Tüm bunlara rağmen çözüm esnasında hata yüzeyi hakkında bilgimiz olmadığı için ulaşılan noktanın yerel mi yoksa genel bir en küçük nokta mı olduğuna karar vermek zordur. Bu yüzden yapılan bir çok çalışmada, hata değerinin artmaya başladığı anda eğitime işlemine son verilir.

Yapay sinir ağları eğitiminde ki diğer önemli bir parametre de öğrenme oranının η , seçilmesidir. Bu oran bağlantı ağırlıklarındaki değişme miktarını kontrol eder. Verimli bir öğrenmenin seçilmesi için öğrenme oranının uygun seçilmesi önemlidir. Çünkü uygun bir η değeri az miktarda bir eğitim ile çözüme götürülebilmesine karşın uygun olmayan bir η değeri de ancak çok fazla eğitim sonucunda çözüme ulaşabilmesine neden olacaktır.

Öğrenme oranı hata fonksiyonu üzerinde minimuma doğru yaklaşırken atılan adımın büyüklüğü olarak ifade edilebilir. Bu oran değerinin küçük tayin edilmesi durumunda bağlantı ağırlıklarında ve hata değerindeki değişim az miktarda olacağından gerçek çözüme ulaşmamız için eğitim sayısını yüksek tutmamız gerekecektir. Bu gibi durumlarda değişim miktarı çok düşük olduğundan dolayı çoğu zaman en küçük noktasına ulaşıldığı düşüncesi ile eğitmenin durdurulması mümkündür. Haykin (1994) η değerinin büyük seçilmesi durumunda, bağlantı

ağırlıklarındaki ani ve hızlı değişimler göstereceğini ve bununda kararsızlığa yol açacağını belirtmektedir.

Öğrenme oranı tayinin en iyi şekilde yapılabilmesi için hata yüzeyinde bulunan noktadaki eğime dikkat edilmelidir. Şayet eğim küçük ise adımların artırılması yani öğrenme oranının büyük seçilmesi en küçük noktasına ulaşılması açısından faydalı olacaktır. Hata yüzeyinde değişim çok düşük olduğundan dolayı büyük adım atılmasında bir sakınca yoktur. Eğim yüksek ise bu defa adımların olabildiğince küçük atılması gerekir. En küçüğe doğru giderken eğimin yüksek olduğu yerde adımın yüksek seçilmesi sıçramalara neden olacağından kararsızlığa yol açabilir.

Yukarıda belirtildiği gibi hata yüzeyi hakkında fazla bir bilgiye sahip olunamayacağından eğimlere göre η değerinin atanması zordur. Bu yüzden yapılan çalışmalarda genellikle 0 ile 1 tercihen 0 ile 0,2 arasında bir değer atanır. Ayrıca eğitme sırasında ortaya çıkacak olan kararsızlık durumlarına göre kontrol yolu ile de η 'nin değeri belirlenebilir. Uygun bir η değeri seçiminin daha az sayıda eğitim ile tasviri gerçekleyebileceği unutulmamalıdır.

Geriye yayılma algoritması güçlü bir öğrenme algoritması olması ve çok yaygın bir şekilde kullanılmasına rağmen bazı mahsurları vardır. Bunlar arasında örneğin, ağıın eğitilebilme garantisi yoktur. Eğitimin gerçekleştirilebilmesi için ağıın büyütülmesinin yeterli olacağı düşünülebilir. Ağıın büyük tutulması öğrenmeyi ne kadar zorlayabileceği hususunda garanti vermemektedir. Ağıın büyütülmesi daha fazla işlem yükü getireceğinden bu kez de sonlu bir zaman diliminde eğitilebilme ihtimali azalmaktadır (ŞEN,Z. 2004).

2.9.13 Levenberg-Marquardt Geri Yayılım Algoritması

Geriye yayılım algoritması, yapay sinir ağlarında en çok kullanılan algoritmadır. Geriye yayılım öğrenmesi sırasında ağ, her giriş örüntüsünü, çıkış sinirlerinde sonuç üretmek üzere gizli katmanlardaki sinirlerden geçirir. Daha sonra çıkış katmanındaki hataları bulabilmek için, beklenen sonuçla, elde edilen sonuç karşılaştırılır. Bundan sonra, çıkış hatalarının türevi çıkış katmanından geriye doğru gizli katmanlara geçirilir. Hata değerleri bulunduktan sonra, sinirler kendi hatalarını azaltmak için ağırlıklarını ayarlar. Ağırlık değiştirme denklemleri, ağdaki performans fonksiyonunu en küçük yapacak şekilde düzenlenir.

İleri beslemeli ağlarda kullanılan öğrenme algoritmaları, performans fonksiyonunu en küçük yapacak ağırlıkları ayarlayabilmek için, performans fonksiyonunun gradyenini kullanırlar. Geriye yayılım algoritması da, ağ boyunca gradyen hesaplamalarını geriye doğru yapar. En basit geriye yayılım öğrenme algoritması gradyen azalması algoritmasıdır. Bu algortmada ağırlıklar, performans fonksiyonunun azalması yönünde ayarlanır. Fakat bu yöntem, pek çok problem için çok yavaş kalmaktadır. Bu algortmadan daha hızlı, daha yüksek performanslı algortmalar da vardır.

Hızlı algortmalar genel olarak iki kategoriye ayrılabilir. İlk kategorideki algortmalar, deneme yanılma tekniklerini kullanarak, standart gradyen azalması (steepest descent) yönteminden daha iyi sonuçlar verebilir. Deneme-yanılma işlemlerini kullanan geriye yayılım algortmaları; momentum terimli geriye yayılım, öğrenme hızı değişen geriye yayılım ve esnek geriye yayılım algortmalarıdır. Hızlı algortmaların ikinci kategorisindeki algortmalar, standart sayısal optimizasyon yöntemlerini kullanır. Bu algortmalar; eşlenik gradyen öğrenme algortması, Newton öğrenme algortmaları ve Levenberg – Marquardt öğrenme algortmasıdır.

Öğrenme algortmaları, kendisinden önce geliştirilen algortmalara alternatif olarak ortaya çıkmıştır ve önceki algortmaların iyi yönlerini geliştirip, kötü yönlerini azaltmaya yönelmiştir. Levenberg – Marquardt algortması da, Newton ve Gradyen Azalması algortmalarının en iyi özelliklerinden oluşur ve kısıtlamalarını ortadan kaldırır.

Eşlenik gradyen öğrenme algortmasına alternatif olarak sunulan Newton yöntemlerinde, temel adım Hessian matrisini elde etmektir. Hessian matrisi, performans fonksiyonunun ağırlıklara göre ikinci dereceden türevlerinden oluşan bir matristir. Hessian matrisi, ağırlık uzayının farklı doğrultularındaki gradyen değişimini gösterir.

$$H(n) = \frac{\partial^2 E(n)}{\partial w^2(n-1)}$$

Burada,

H Hessian matrisi,

E performans fonksiyonu ve

w ağırlık sinaptik ağırlığıdır.

Performans fonksiyonu, duruma göre toplam ani hata veya ortalama karesel hata olarak alınabilir. Bu çalışmada, ileri beslemeli ağların çoğunda olduğu gibi, performans fonksiyonu olarak, ortalama karesel hata kullanılmıştır.

$$E(n) = E_{ort}(n) = \frac{1}{N} \sum_{n=1}^N \frac{1}{2} \sum_{j \in C} e_j^2(n)$$

Burada N eğitim kümesindeki toplam örüntü sayısını, e_j hata işaretini, C ağın çıkış katmanındaki bütün sinirleri içeren kümeyi göstermektedir. d_j istenen değer, y_j ağın çıkışı olmak üzere hata işareti,

$$e_j(n) = d_j(n) - y_j(n)$$

olarak bulunabilir. Hessian matrisi hesaplandıktan sonra, tersi bulunarak ağırlıklar yenilenebilir. Ancak Hessian matrisi çok karmaşık ve ileri beslemeli bir yapay sinir ağı için hesaplanması zor bir matristir. Newton yöntemlerinin içinde, ikinci dereceden türevlerin hesaplanmadan işlem yapılan bir sınıf vardır. Bu sınıftaki yöntemler, Quasi-Newton yöntemleri olarak adlandırılırlar. Quasi-Newton yöntemleri, algortimanın her iterasyonunda, Hessian matrisinin yaklaşık bir şeklini kullanır.

Levenberg-Marquardt algoritması da Quasi-Newton yöntemleri gibi, Hessian matrisinin yaklaşık değerini kullanır. Levenberg-Marquardt algoritması için Hessian matrisinin yaklaşık değeri şu şekilde bulunabilir:

$$H(n) = J^T(n)J(n) + \mu I$$

denklemindeki μ Marquardt parametresi, I ise birim matristir. Burada J matrisi, Jakobien matrisi olarak adlandırılır ve ağ hatalarının ağırlıklara göre birinci türevlerinden oluşur:

$$J(n) = \frac{\partial e(n)}{\partial w(n-1)}$$

denkleminde e , ağ hataları vektörüdür. Jakobien matrisi, hesaplamada Hessian matrisinden daha kolay olduğu için tercih edilir. Ağın gradyeni,

$$g(n) = J^T(n)e(n)$$

olarak hesaplanır ve ağırlıklar aşağıdaki denkleme göre değiştirilir:

$$w(n+1) = w(n) - [H(n)]^{-1} g(n)$$

Marquardt parametresi, μ , skaler bir sayıdır. Eđer μ sıfırsa, bu yöntem yaklaşık Hessian matrisini kullanan Newton algoritması; eđer μ büyük bir sayı ise, küçük adımlı gradyen azalması yöntemi haline gelir. Newton yöntemleri, en küçük hata yakınlarında daha hızlı ve kesindir. Her başarılı adımdan sonra, yani performans fonksiyonunun azalmasında μ azaltılır ve sadece deneme niteliğindeki bir adım performans fonksiyonunu yükseltecekse μ arttırılır. Bu yöntemle, algoritmanın her iterasyonunda, performans fonksiyonu daima azaltılır.

Genel olarak Levenberg–Marquardt algoritması yavaş yakınsama probleminden etkilenmez. Burada hedef, performans fonksiyonunu en küçük yapacak ağırlık değerini bulmaktır (Bolat,S.&Kalenderli,Ö. 2003).

3. METODOLOJİ

Bu bölüm, kara kutudan alınan bilginin kullanılarak uçağın yakıt tüketimini tahmin etme sürecinin örneklenmesinde kullanılan prosedürleri belirlemektedir. Bu tezin hedeflerini yakalamada kullanılan genel yaklaşımlar, araçlar ve metotlar aşağıdaki basamaklarla gösterilmiştir:

1. Test uçağının seçilmesi
2. Kara kutudan ilgili parametrelerin alınması
3. Uygun veri tabanı için yapay sinir ağlarının eğitilmesi
4. Yapay sinir ağları ile yakıt tüketiminin hesaplanması için, yapay sinir ağları çıkışlarının elde edilmesi
5. İstatistiksel analizin uygulanması
6. Sonuçların uygulanması

3.1 Test Uçağının Seçilmesi

Bu araştırma için orta boy gövdeli ve orta menzilli bir jet uçak için seçilmiştir. Sivil hava taşımacılığı yapan bu uçağın ana özellikleri Tablo 3.1’de gösterilmiştir (Boeing AMM,b). Boeing 737-800 uçağı iki adet CFM56-7B gaz türbinli yüksek bypass oranlı turbofan tipi gaz türbinli motor ile güçlendirilmiştir. Motorların herbirinin 26300 pound’luk itki gücü bulunmaktadır. Maksimum operasyon hızı 925 km’dir ya da Mach 0,82’dir.

Şekil 3.1: Uçağın Fiziksel Görünümü



Tablo 3.1: Uçak Karakteristik Değerleri

Uçak Karakteristikleri	Değerler
Yükseklik	12,598m
Uzunluk	33,630m
Kanat Açıklığı	34,315m
Motorun Yerden Yüksekliği	0,627m
Cruise Hızı	925km
Azami Kalkış Ağırlığı	79015kg
Menzili	5420km
Yolcu Kapasitesi	160-189
Max. Yakıt Kapasitesi	26,020L
Kabinin İç Genişliği	3,53m
Motor Sayısı	2
Motorları	CFM56-7B

3.2 Kara Kutudan İlgili Parametrelerin Alınması:

3.2.1 Kullanılan Kara Kutunun Tanımı

Bu uçakta kullanılan kara kutu L3 Communications firmasının ürettiği F1000 SSFDR (Solid State Flight Data Recorder) modelidir. Üretici parça numarası S903-2000'dir. SSFDR'lar yarı iletken flash memory teknolojisini kullanır. Bu model bilgiyi ARINC 573/717/747 FDAU'dan alır ve ARINC 542A modunda işlem yapar. Ebatları 21,5x4,88x7,62 inçtir. Ağırlığı 25,4 pounddur. Bu karakatuda diğer uçaklardan farklı olmak üzere 920 tane parametre kayıt altında tutulmaktadır (L3 Commuations CMM).

3.2.2 Kara Kutudan Bilgilerin İndirilmesi

Kara kutuda bulunan yüzlerce parametreden, bir uçuş sürecini kapsayan ilgili parametrelerin bu çalışma için indirilmesi gerekmektedir. Uçağın bazı parametrelerinin sürekli takip altında olması için FDR aracılığı ile download edilmesi bir gerekliliktir. Bu parametreler uçak sistemlerinin emniyet ve güvenilirliğinin kontrol altında tutulmasını sağlar. FDR'dan download edilen veriler, uçak sistemlerinden gelen analog bilgilerin FDAU tarafından dijital dataya dönüşmüş halidir. Bu download işleminde kullanılan arayüz HHDLU (Hand Held Download Unit) isimli bir cihazdır. Uçağın kuyruk konisinde bulunan FDR üzerinde, HHDLU

bağlantısının sağlanması için bir konnektör bulunmaktadır. Bu cihaz sadece mandatory denilen birincil derecede önem arz eden verileri PCMCIA veri depolama kartına kaydeder. Mandatory parametrelerin sayısı ihtiyaca bağlı olarak üretici firma tarafından artırılıp azaltılabilir. 512 mb kapasiteye sahip olan bu kartlardaki bilgiler ilgili bakım atelyesinde ADRAS adı verilen bir program ile CSV formatındaki dosyalara dönüştürülmektedir. Bilgilerin analizi bu format ile en kolay şekilde yapılmaktadır. ADRAS ile veriler istenen formata dönüştürülürken satırlar arasındaki okuma periyodu kullanıcı tarafından saniyenin 1/16'sı oranına kadar düşürülebilir. Bu çalışma için 1 saniyelik periyotla verinin okunması yeterli olacaktır ve gerekli olan tüm parametreler mandatory parametrelerin içerisinde mevcuttur.

3.3 Yapay Sinir Ağlarının Eğitilmesi

3.3.1 Uygulamanın Yapılacağı Programın Seçilmesi

Çalışmamızda; daha önce Schilling'in yaptığı modele alternatif olarak MATLAB yerine Neurosolutions 5.0 programı tercih edilmiştir. C ve PASCAL gibi yüksek seviyeli bilgisayar programları ile aynı çalışma yapılabilirdi fakat bu programın yapay sinir ağlarına özgün olması çalışmanın hızlı ilerlemesinde etkin rol oynamıştır. Benzer diğer yapay sinir ağları programları yerine bu programın kullanılması, sinir ağı modellemesinde aşağıdaki olanakları sağlayacaktır:

1. Ağın eğitimi/öğrenmesi
2. Eğitilmiş ağın test edilmesi ve değerlendirilmesi
3. Uçağın yakıt tüketiminin hesaplanması için uygulama

3.3.2. Algoritmaların seçilmesi

Levenberg-Marquardt algoritmaları bu çalışmalar için en güvenilir ve etkili araç olarak tespit edilmiştir. Tablo 3.2, incelenmiş en popüler üç algoritmanın birbiri ile kıyaslamasını gösterir. Bu sayılar Macintosh Quadra 950 tarafından çalıştırılan MATLAB versiyon 4.2'ye dayandırılmıştır. (Trani,A., 2004)

Tablo 3.2: Optimizasyon Algoritmalarının Karşılaştırılması

Fonksiyon	Teknik	Süre (sec)
TRAINBP	Back-propagation	259.1
TRAINBPX	Fast Back-propagation	42.4
TRAINLM	Levenberg-Marquardt	3.3

Bu yüzden, Levenberg-Marquardt Algoritması tasarım tercihidir.

3.3.4 Uygun Sinir Ağı Topolojisi Dizaynı

Uygun yapay sinir ağı topolojisi dizaynı aşağıdaki basamakları içerir:

1. Uygun transfer fonksiyonunu seçme,
2. Her katmanda kullanılacak sinir miktarına karar verme,
3. Gizli katmanların miktarını seçme.

Tipik olarak, iki yada üç katmanlı ağ sınırlı sayıdaki veriler ile herhangi bir fonksiyonu yaklaştırma için yeterlidir. Her bir katmanın sinir sayısının miktarı hedef işlemin karışıklığına bağlıdır. Eğer her katmanda yeterli sinir yoksa çıktı bütün veri noktalarını kapsayamayacaktır. Diğer taraftan, eğer her bir katmanda çok fazla sinir varsa veriler arasında osilasyon olabilir. Bu yüzden, bu proje için en uygun mimariyi bulmak için bir topoloji araştırması yapılmak zorundadır

Tablo 3.3: Yapay Sinir Ağı Topoloji Adaylarının Listesi ve Onlara Karşılık Gelen Sayısal Performanslar (Trani,A., 2004).

Katman Sayısı	Sinir Sayısı	İsim	Transfer Fonksiyonları	Ortalama Hata (%)	Standart Sapma Hatası (%)
2	4	NN 2-4	tansig-purelin	0.611	0.0282
2	6	NN 2-6	tansig-purelin	0.606	0.0281
2	8	NN 2-8	tansig-purelin	0.628	0.0288
3	4	NN 3-4	logsig-tansig-purelin	0.617	0.0288
3	6	NN 3-6	logsig-tansig-purelin	0.610	0.0280
3	8	NN 3-8	logsig-tansig-purelin	0.604	0.0279
3	10	NN 3-10	logsig-tansig-purelin	0.656	0.0290
3	12	NN 3-12	logsig-tansig-purelin	0.667	0.0295

Yukarıdaki tabloya göz atıldığında en iyi topoloji adaylarının NN 2-6 ve NN 3-8 çifti olduğu görülmektedir. Bunların hata ortalaması %0.606 ve %0.604'dür. Her ikisinin de hata ortalamasının düşük olmasına rağmen yapılan 10000 epochluk bir çalışmanın ardından her ikisinin de minimum hata noktasında birleşmediği görülmüştür ve bu yüzden bu araştırma için nihai karar, ilk iki katmanında sekiz sinir ve çıktı katmanında bir sinir olan 3 katmanlı bir topoloji tercih edilmiştir. Buna karşılık gelen transfer fonksiyonları ise; logaritmik sigmoid, tanjant sigmoid ve doğrusal aktivasyon fonksiyonudur.

3.4 Yapay Sinir Ağı Uygulaması

Yakıt tüketimini değerlendirme modelinde başvuru yapılan yapay sinir ağı, girdi verilerinin doğrusal olmamasından dolayı doğrusal olmayan transfer tabanlıdır. Yapay sinir ağı ile üzerindeki bütün ağırlıkları tahmin ederken modelimiz doğrusal olmayan bir programlama tekniği kullanır. Bu optimizasyonun amacı; ağı parametrelerini, ağırlıkları (w) ve biasları (b) alıştırılarda eğitmektir ki böylece bunlar ağı performansının optimizasyonunu çalışmalarına uyarlayabilecektir. Yapay sinir ağı parametreleri ağırlıklar ve biaslardaki değişikliklere uyum sağlayacak şekilde eğitilmişlerdir. Böylelikle doğru bir şekilde her yenilemede çıktı yeniden şekillendirebilir ve hedef ile arasındaki hatanın minimize edilerek hedeflenen sonuç elde edilene kadar küçülmesi sağlanır.

Yapay sinir ağı modeli hakkındaki genel şartlar aşağıdaki gibidir:

- Anlaşılabilir ve kolay bir kullanım,
- Geniş çapta bir uçak çeşidi için kolayca uyarlanabilirlik,
- Değiştirmesi ve güncellenmesi kolay bir model.

Faydalı bir model için yukarıda bahsedilen ifadeler mutlaka gerçekleştirilmelidir.


3.4.1 Kullanılacak Veri Tabanının Analizi

Kara kutudan indirilen uçuşların, kalkıştan inişe kadar aynı özellikleri ve şartları taşımadığı gerekçesi ile havacılıkta olduğu gibi bu araştırmada da bir uçuş 6 faza bölünerek, daha doğru değerler almak için ayrı ayrı incelenmiştir. Bunlar:

- Taxiing (Taksi)
- Take-off (Kalkış)
- Climb (Tırmanma)
- Cruise (Düz Uçuş)
- Descent (Alçalma)
- Landing (İniş)

Şekil 3.2’de irtifaya bağlı olarak uçuş fazları gösterilmiştir.

Şekil 3.2: Uçuş Fazları



3.4.1.1 Taxiing Fazı

Taksi (Taxiing), bir uçağın yerde kendi gücü ile hareket etmesidir. Uçak genelde tekerlekler üzerine hareket eder fakat bu terim ayrıca deniz uçakları içinde suyun üzerinde kayma hareketine verilen isimdir.

Uçak taksi hareketi boyunca, bir yerden bir diğerine giderken taksi yolunu kullanır. Örneğin, bir terminalden koşu pistine (runway) kadar yaptığı hareket taksidir.

Pervaneli motorlar veya jet motorları tarafından oluşan itki ile uçak ileri doğru hareket eder. Uçağın yerdeki yönlendirme hareketi (steering), burunda bulunan tekerleklerin hareketi ile veya hızlı olduğu durumlarda uçağın arkasındaki rudder ile sağlanır (Wikipedia, e).

3.4.1.2 Take-off Fazı

Kalkış (Take off), genelde bir koşu pisti (runway) üzerinde bir uçağın, taksi fazından sonra yerden ayrılarak havada uçana kadar koşturulmasıdır. Balonlar, helikopterler ve bazı özel uçak modelleri için (Harrier gibi dikey havalanan modeller) koşu pistine (runway) ihtiyaç yoktur. Kalkış fazı, inişin tam zıddıdır.

Hafif uçaklarda kalkış esnasında tam güç verilir. Geniş gövdeli, ticari hava taşımacılığında kullanılan uçaklarda genellikle tam gücün bir alt kademesindeki itki kullanılır. Tam güç acil durumlarda kullanılmak için saklanır. Kalkıştan önce motorlar çalıştırılarak yüksek güç uygulanıp güvenilirlik açısından arıza durumları kontrol edilir (Wikipedia, f).

3.4.1.3 Climb Fazı

Tırmanma (Climb), bir uçağın kalkıştan sonra istenen uçuş irtifa seviyesine ulaşana kadar ki uçuş dilimine verilen isimdir. Daha genel olarak tırmanma terimi irtifanın artması olarak kullanılır.

Bir pilot genellikle uçağın tırmanmasını sağlarken, uygun hız için kuyruktaki elevatörlerin açısını uygun yunuslama açısına ve itki gücünü gereken değere ayarlamalıdır.

Uzun tırmanmalar esnasında tırmanma açısı sık sık düşürülür. Çabuk tırmanmanın faydası ise görüşün açılması ve bulut tabakasından ayrılarak türbülanslı havadan çıkılmış olmasıdır fakat pilot çok hızlı bir şekilde tırmanmak isterken stall'a sebebiyet verebilir. Stall ise uçağın taşıma kuvvetinin azalarak, uçağa kumanda verilemeyip kontrolünün kaybedilmesi durumudur. Tırmanma fazının tam zıddı ise alçalma (descent) olarak adlandırılır (Wikipedia, g).

3.4.1.4 Cruise Fazı

Düz uçuş (Cruise) fazı, bir uçağın yakıt tüketiminin en verimli olduğu uçuş safhasıdır. Bu faz kalkış ve iniş safhalarının arasında kalan bölümdür ve genellikle bir seyahatin en büyük kısmı düz uçuştan oluşur. Teknik olarak düz uçuş fazı, uçağın baş açısına ve sabit değerde olması istenen hız ve irtifa parametrelerine bağlıdır. Bu faz uçağın menziline yaklaşarak alçalmaya başlaması ile son bulur.

Bir ticari yolcu uçağı yakıtının büyük kısmını uçağın düz uçuş fazında kullanır. Yüksek irtifaların yakıt ekonomisi açısından daha faydalı olduğu düşünülür. Halbuki, operasyonel ve hava trafik kontrol sebeplerinden dolayı daha açık irtifa seviyelerinde kalması uygun görülür. Uzun süreli uçuşlarda, hava trafik kontrolöründen açık olduğuna dair onay gelirse pilot periyodik olarak bir üst irtifa seviyesine tırmanabilir (Wikipedia, h).

3.4.1.5 Descent Fazı

Alçalma (Descent) fazı, bir hava yolculuğunda irtifanın düştüğü bölümdür. Tırmanma (climb) fazının tam tersi olarak bilinir. Normal alçalma sabit bir hız ve uygun yaklaşma açısı ile yapılmalıdır. Havalimanlarının çoğunda son yaklaşma açısı 3 derecedir. Pilot hızı sabit tutarak, değişen motor gücü ve yunuslama açısı ile yaklaşma açısını kontrol eder. Motor gücü olmadan (motorların arızalandığı durumda) normalden daha dik bir iniş yapılmaktadır. Böyle bir konumda uçak planör gibi seyrini sürdürerek yaklaşır. Eğer uçağın burnu çok kaldırılırsa, uçak stall'a girer ve taşıma kuvveti kaybolacağından hız da düşer (Wikipedia, i).

3.4.1.6 Landing Fazı


İniş (Landing) fazı, bir uçuşun son bölümü yani uçan cismin yere geri dönüşüdür. Uçan cismin inişi suya ise buna “alighting” denses bile, iniş işlemi genellikle “landing” veya “touchdown” olarak adlandırılır. İniş esnasında uçağın burnunu hafiften kaldırarak inmesine “flame” denmektedir (Wikipedia, j).

Bir uçağın inişi için pistin uzunluğu önemlidir. Uçağın havalimanına geldiği ağırlıkla inişte pistin sonuna varmadan durması gerekmektedir. Büyük gövdeli ve uzun menzil uçacak uçaklar (Airbus A300, Airbus A340 gibi), kalktıktan hemen sonra herhangi bir nedenden dolayı kalktığı piste inmesi gerekirse depolarındaki yakıtın büyük bir bölümünü boşaltmak zorundadır. Çünkü kalkmadan önce uçağın yolda tüketeceği yakıt düşünülerek, gideceği yere iniş ağırlığı hesaplanmıştır. Eğer o ağırlıkla kalktığı piste geri iniş yaparsa uçak pist dışına çıkar. Orta ve küçük gövdeli uçaklarda böyle bir sorun olmadığından onlara havada yakıt boşaltımının yapılacağı sistem eklenmemiştir.

3.4.2 Yakıt Tüketim Modelinde Kullanılacak Sinir Ağının Tanımı

Her bir faz için eğitilmiş bir yapay sinir ağı ağırlık ve biasları vardır. Eğitim maksatlı ham bilgi kara kutudan (FDR) elde edilmiştir ve yapay sinir ağını denemek için girdi olarak kullanılmıştır. Levenberg-Marquardt yaklaşım modeli ile bir geriye dönük yayılıma başvurulmuştur. Bu modelin seçilme sebebi; ağırlık biaslar, sigmoid katmanları ve doğrusal olmayan çıktı katmanları ile sınırlı sayıda veriyi barındıran herhangi bir işlemi yakınlığa yetkin olmasıdır. Levenberg-Marquardt yaklaşım Newton’un metodunu kullanarak deneme süresini kısaltan doğrusal olmayan bir yakınlığa şeklidir. Şekil 3.3’de üç katmanlı yakıt tüketim ağı yapıyı gösterilmektedir.

Şekil 3.3: Üç Katmanlı Genel Yapay Sinir Ağı



Burada:

P, girdi vektörüdür.

Z_i , i^{th} katmanındaki sinir sayısıdır, $i=1,2,3$ için. Örn, $Z_1=8$, $Z_2=8$ ve $Z_3=1$.

F1, logaritmik sigmoid transfer fonksiyonu,


F2, tanjant sigmoid transfer fonksiyonu ve

F3, doğrusal transfer fonksiyonudur.

Farklı uçuş fazları farklı girdiler gerektirse bile, deneme prosedürü aynı kalır. Bu ağ bir kere geliştirildiği zaman uçağın yakıt tüketme tahmini oldukça kolaydır.


Motor çalıştırma ve taksi için, doğrusal orantı sonuçları kullanılarak yakıt akış oranı hesaplanır. Doğrusal orantı kullanma sebebi bu fazda yakıt tüketim oranının ve başlangıç ağırlığının doğrusal ilişkiler göstermesidir. Eğim ve y-kesişme noktaları bulunduğu zaman herhangi bir başlangıç ağırlığı için ona karşılık gelecek bir yakıt oranı olacaktır (Şekil 3.4'e bkz.). Yakıt akış oranı ile uçuş için piste hareket etme süresinin çarpımı bu faz için toplam yakıt tüketim miktarını verir.

Şekil 3.4: Taksi Fazı Yakıt Tüketim Grafiği




Bir önceki uçuş fazından kalan nihai uçuş ağırlığı ile tekerleklerin yerden kesilmesi ve tırmanmanın başlamasına kadar ki süre de kullanılan yakıt tüketiminin bulunabilmesi için bir yapay sinir ağı kullanımına ihtiyaç vardır. Bu da Şekil 3.5 ile ifade edilmiştir.

Şekil 3.5: Take-off Fazı Yakıt Tüketim Diyagramı




Tırmanmanın başlamasından uçuş irtifasına kadar yakıt tüketimi uçağın ağırlığı (Gross Weight), irtifa (Altitude), Sıcaklık (TAT) ve uçağın hızı (Mach Number) bilgileri kullanılarak eğitilmiş bir yapay sinir ağı tarafından hesaplanmaktadır (Şekil 3.6). Bu bölüm yakıt akış oranının en yüksek olduğu uçuş fazıdır. Kalkış esnasında motorlara tam itki (full thrust) uygulanır.

Şekil 3.6: Climb Fazı Yakıt Tüketim Diyagramı



Uçağın düz uçuş fazında (cruise) hız bilgisi olarak özellikle airspeed yerine mach number tercih edilmektedir. Kaptanlar daha gerçekçi bir uçuş hızı bilgisi kullanmak istediğinden belirli bir irtifanın üzerinde mach sayısını, airspeed'e tercih etmektedirler

Şekil 3.7: Cruise Fazı Yakıt Tüketim Diyagramı



Alçalma (descent) ve iniş (landing) fazları için yakıt tüketimi tırmanma (climb) ve kalkış (take off) aşaması gibidir, bu yüzden detaylar burada tekrar edilmeyecektir.

Yukarıda ana hatları çizilen basamaklar göstermektedir ki yakıt tüketim tahminleri için sinir ağı kullanımı Collins algoritmasında görülen bütün katsayıların hesaplanmasından daha kolaydır.

3.4.3 Özet

Tablo 3.3 farklı uçuş segmentlerinin ağını ve buna karşılık gelen girdi ve çıktılarının eğitim ve test verilerinin özetini içermektedir.

Kara kutudan alınan uçuşlardan birisi örnek teşkil etmesi için seçilerek uygulamalar onun üzerinde yapılmıştır. Onunla alakalı yapılan ağ eğitimi ve eğitimle alakalı testler hakkındaki verileri Tablo 3.3'de görülmektedir. Farklı uçuş fazlarından alınan test noktaları da bu tabloda mevcuttur.

Tablo 3.4: Uçuş Fazlarının Eğitim ve Test Verileri

Uçuş Fazı	Eğitim Noktası Sayısı	Test Noktası Sayısı	Giriş Parametreleri	Çıkış
Take-off	126	50	Uçağın Ağırlığı Hava Hızı İrtifa	Yakıt Akış Miktarı (lb/min.)
Climb	285	114	Uçağın Ağırlığı Mach Sayısı Sıcaklık İrtifa	Yakıt Akış Miktarı (lb/min.)
Cruise	1870	748	Uçağın Ağırlığı Mach Sayısı Sıcaklık İrtifa	Yakıt Akış Miktarı (lb/min.)
Descent	472	189	Uçağın Ağırlığı Mach Sayısı Sıcaklık İrtifa	Yakıt Akış Miktarı (lb/min.)
Landing	45	18	Uçağın Ağırlığı Hava Hızı İrtifa	Yakıt Akış Miktarı (lb/min.)

3.5 İstatistiksel Analizin Uygulanması

Korelasyon analizinde, bir anakütleden seçilmiş en az iki veya daha fazla örnek grup alınarak, bu gruplar arasındaki etkileşime bir katsayı yardımıyla bakılmaktadır. Bu katsayı korelasyon katsayısıdır ve r ile gösterilmektedir.

Korelasyon analizinin yapılacağı gruplar (bunlara değişken de denilebilir) arasında etkileşime bakılırken, bağımlı değişken veya bağımsız değişken olma şartı aranmamaktadır. Korelasyonuna bakılacak olan değişken gruplar ikiden fazla olsalar dahi ikili olarak ele alınıp ve bu ikili değişkenlerin etkileşimi, katsayı yardımıyla yön ve kuvvet olarak tayin edilmektedirler.

Korelasyon katsayısı, değişkenlerin yönü, etkileşimlerin nasıl olduğu hakkında bilgi vermektedir. Değişkenlerin birbiri arasında etkileşim var mı, varsa etkileşimin kuvvetli olup olmadığı ve gözlem gruplarından birinin gözlem değerleri artarken diğerinin azalıyor mu, yoksa değerlerinin aynı yönde mi değiştiği gözlemlenebilmektedir.

Korelasyon katsayısı -1 ile +1 arasında değişen değerler almaktadır. Katsayı, etkileşimin olmadığı durumda 0, tam ve kuvvetli bir etkileşim varsa 1, ters yönlü ve tam bir etkileşim varsa -1 değerini alır. Anakütleye göre normal sayılacak kadar bir gözlem sayısı alınarak bakılmış gözlem grupları için genellikle, 0-0.49 arasında ise korelasyon zayıf, 0.5-0.74 arasında ise orta derecede, 0.75-1 arasında ise kuvvetli ilişki vardır denilmektedir.

Bu çalışmada elde edilen değerlerle gerçek değerler arasında korelasyon analizi uygulanarak ikisinin arasındaki bağın kuvveti incelenmektedir.

3.6 Sonuçların Uygulanması

Tek bir sinir için geçerli olan kavramları, katmanlara uygulanırsa, her bir katman kendisinin eğitilmiş ağırlık matrisine W , kendisinin bias vektörüne b , bununla birlikte transfer işlemine f , girdi vektörüne p ve çıktıya a sahiptir. Bundan:

$$a = f(Wp + b)$$

şeklinde bahsedilebilir. Üç katmanlı sekiz sinirli bir ağdan ve üçüncü katmandaki bir sinirden faydalanılacaktır. Onlara karşılık gelen transfer işlemleri ilk katman için logaritmik-sigmoid, ikinci katman için tanjant-sigmoid ve üçüncü katman için doğrusal aktivasyon fonksiyonudur. Ağın nasıl çalıştığını göstermek için uçuşun tırmanma safhası kullanılacaktır. Önceden de bahsedildiği gibi bu aşamanın girdileri uçağın ağırlığı, mach sayısı, irtifa ve TAT bilgisidir. Çıktı ise yakıt akışıdır. Bu yüzden bu model dört giriş parametresini sentez edebilmeli ve bir çıktı vermelidir. Buna karşılık gelen mimari şekil 3.7'de gösterilmiştir.


Burada

f1 - logaritmik-sigmoid transfer işlemi (SigmoidAxon)

f2 – tanjant-sigmoid transfer işlemi (TanhAxon)

f3 – doğrusal transfer işlemi (LinearAxon)

Şekil 3.7: Seçilmiş Sinir Ağı Mimarisi



Şekil 3.7 uçak yakıt tüketimi hesaplamasında kullanılacak üç katmanlı ağdan faydalandığını göstermektedir. Birinci ve ikinci katmanların çıktıları, ikinci ve üçüncü katmanların girdileridir. Böylelikle katman 2, sekiz girdili, sekiz sinirli ve 8×8 ağırlık matrisli bir tek katmanlı ağ olarak gözlenebilir. Katman ikinin girdisi a^1 ve çıktısı a^2 . Buna dayanılarak bu örnekteki üç katmanlı ağ aşağıda ifade edildiği gibi yazılabilir:

$$fuelflow = a^3 = f_3(W^3 f_2(W^2 f_1(W^1 p + b^1) + b^2) + b^3)$$

Burada,

$$W^1 = \begin{bmatrix} w_{1,1}^1 & w_{1,2}^1 & \dots & w_{1,8}^1 \\ w_{2,1}^1 & w_{2,2}^1 & \dots & w_{2,8}^1 \\ w_{3,1}^1 & w_{3,2}^1 & \dots & w_{3,8}^1 \\ w_{4,1}^1 & w_{4,2}^1 & \dots & w_{4,8}^1 \end{bmatrix}, \quad W^2 = \begin{bmatrix} w_{1,1}^2 & w_{1,2}^2 & \dots & w_{1,8}^2 \\ w_{2,1}^2 & w_{2,2}^2 & \dots & w_{2,8}^2 \\ \dots & \dots & \dots & \dots \\ w_{8,1}^2 & w_{8,2}^2 & \dots & w_{8,8}^2 \end{bmatrix} \quad \text{ve} \quad W^3 = \begin{bmatrix} w_{1,1}^3 \\ w_{2,1}^3 \\ \dots \\ w_{8,1}^3 \end{bmatrix}.$$

Bu yüzden ilk katmandaki ilk sinir için çıktısı a_1^1 şeklinde ifade edilebilir:

$$a_1^1 = f1 \left(\left[w_{1,1}^1 w_{1,2}^1 w_{1,3}^1 w_{1,4}^1 \right] \begin{bmatrix} \textit{Altitude} \\ \textit{Mach} \\ \textit{Temprature} \\ \textit{Weight} \end{bmatrix} + b_1^1 \right)$$

Ayrıca,

$$f1(n) = \frac{1}{1 + e^{-n}}$$

Bu sebeple ,

$$a_1^1 = \frac{1}{1 + e^{- \left(\left[w_{1,1}^1 w_{1,2}^1 w_{1,3}^1 w_{1,4}^1 \right] \begin{bmatrix} \textit{Altitude} \\ \textit{Mach} \\ \textit{Temprature} \\ \textit{Weight} \end{bmatrix} + b_1^1 \right)}}$$

diğer bütün uçuş aşamalarındaki yakıt tüketimi aynı prensibe dayandırılacaktır ve bu nedenle burada yeniden tekrarlanmayacaktır.

4. MODELİN UYGULANMASI

Bu bölüm araştırma projesi için kurulan bilgisayar programını tanıtacaktır ve geliştirilen ağ modelinin eğitilmesi, test edilmesi ve yakıt tüketim tahminini içerecektir. Sinir ağı modelini oluşturmak için modelleme programı olarak Neurosolutions 5.0 kullanılmıştır. Bu program yapay sinir ağları için tasarlanmıştır ve içinde yapay sinir ağlarında kullanılan tüm fonksiyonlar mevcuttur.

Aşağıdaki adımlar yakıt tüketimi için sinir ağı uygulanmasında seçilen prosedürleri özetleyecektir.

a) Farklı uçuş fazları için sinir ağının eğitimi:

- Kalkış
- Tırmanma
- Düz uçuş
- Alçalma
- İniş

b) Eğitilen ağın kullanılması

4.1 Farklı Uçuş Fazları İçin Ağın Eğitimi

Bu bölümde program, geliştirilen sinir ağının eğitimi yapmak için kullanılacaktır. Programın girişleri, kara kutudan elde edilen verilerin öğrenme setidir. 3. bölümde üzerinde durulduğu gibi sinir ağı ile ilgili aşağıdaki ifadeler de yapay sinir ağının oluşturulmasında program tarafından giriş olarak istenecektir.

1. Girişlerin ve çıkışların sayısı
2. Kullanılacak katman sayısı
- 3- Gizli ve çıkış katmanlarındaki işlem elemanlarının sayısı
- 4- Her çalışma için periyot sayısı ve eğitim sayısı

Programı kullanırken ilk olarak modeli isteyecektir. Burada geri dönüşümlü ağ (recurrent network) tercih edilmektedir.

Bir sonra ki adımda girişler istenmektedir. Genelde eğitilen ağda 4 giriş kullanılmıştır. Bunlar; irtifa (altitude), mach sayısı (mach number), ağırlık (gross weight) ve sıcaklık (total air temprature) bilgileridir. Genelde denmesinin sebebi kalkış ve inişte sıcaklık sabit olduğu için bunlar değişken olarak alınmamış sadece irtifa, hız ve yakıt kullanımıyla birlikte uçağın zaman içinde azalan ağırlığı

kullanılmıştır. Bunun dışındaki diğer uçuş fazlarında bahsi geçen 4 girişte kullanılmıştır. Çıkış ise hepsinde ortak ve tek olan yakıt akışı (fuel flow) alınmıştır.

Ağırlık matrisi eğitimi veya yapay sinir ağının öğrenme işlemi için ilk adım bilginin programa alınmasıdır. İndirilen yüzlerce veriden daha önceki bölümlerde bahsedildiği gibi yakıt tüketimi ile birinci dereceden alakalı olan parametreler seçilerek ayrılır ve programa sadece bunların girişi yapılır. Örnek teşkil etmesi açısından burada sadece bir uçuşun değerleri ve sonuçları gösterilmektedir. Hazırlanan ağ modeli ile tüm uçuşların test işlemi yapıp onlardan alınan neticeler doğrultusunda bir değerlendirme yapılmıştır. Uçuşlardan birisi eğitim seti olarak kullanılmıştır. Diğer uçuşlar ile de yapılan test ve tahminler görülecektir.

Giriş ve çıkışların belirtilmesinden sonra kullanılacak katman sayısı girilir ve bu katmanların herbirinde kullanılan transfer fonksiyonlarının yanısıra her bir katmanın eleman sayısı burada tanımlanır. Bölüm 3'te belirtildiği gibi sekizer elemanı olan iki gizli katman ve bir çıkış katmanı seçimi ile bu basamak geçilir. Ayrıca burada öğrenme algoritmasını söylemek gereklidir. Bu da, daha önceden tayin edilen Levenberg-Marquardt algoritmasıdır.

Programda, ağın eğitilmesi sırasında işlemlerin izlenmesi için giriş, çıkış ve hataların ne şekilde gözlemlenmek istediği belirtilir. Çizelge, grafik, sayısal değerler gibi seçenekler bulunur.

Ağın eğiteleceği periyot sayısı ve eğitimin kaç defa tekrarlanacağı da burada belirtilir. Bu çalışmada, eğitimden güzel sonuçlar alınması için ağın 5 defa eğitimi yapılmıştır ve maksimum epoch sayısı 1000 olarak atanmıştır.

Değişik uçuş safhaları farklı girişler gerektirdiğinden, her bir uçuş safhasındaki uygun ağırlık matrisini üretmek için özel eğitim işlemi gereklidir. Tablo 4.1 bütün uçuş safhaları için gerekli giriş ve çıkış parametrelerinin özetini gösterir:


Tablo 4.1: Giriş ve Çıkış Parametrelerinin Özeti

Uçuş Fazı	Giriş Parametreleri	Çıkış Parametreleri
Take-off	Uçağın Ağırlığı Hava Hızı İrtifa	Yakıt Akış Miktarı (lb/min.)
Climb	Uçağın Ağırlığı Mach Sayısı Sıcaklık İrtifa	Yakıt Akış Miktarı (lb/min.)

Uçuş Fazı	Giriş Parametreleri	Çıkış Parametreleri
Cruise	Uçağın Ağırlığı Mach Sayısı Sıcaklık İrtifa	Yakıt Akış Miktarı (lb/min.)
Descent	Uçağın Ağırlığı Mach Sayısı Sıcaklık İrtifa	Yakıt Akış Miktarı (lb/min.)
Landing	Uçağın Ağırlığı Hava Hızı İrtifa	Yakıt Akış Miktarı (lb/min.)

Çıkışlar daha sonra karşılık gelen performans noktaları için farklı bir uçuşun kara kutu dosyasından alınan gerçek değerler ile karşılaştırılır ve bunların kıyaslanması ayrıca grafik aracılığı ile de yapılır. Kalkış bölümü için 126, tırmanma bölümü için toplam 285 performans noktasıyla ağ eğitilmiştir. Düz uçuş bölümü için nöral ağı eğitilmesinde toplam 1870 performans noktası kullanılır. Son olarak, alçalma bölümü için kullanılan toplam 472 ve iniş bölümü için 45 performans noktası ile ağ eğitilmiştir. Aşağıdaki şekilde geliştirilen modelin eğitiminin yapıldığı uçuşun irtifa ve eğitim noktalarına bağlı uçuş profili bulunmaktadır. Bu grafikte modelde ayrı ayrı eğitiminin yapılacağı tüm uçuş fazları bulunmaktadır.

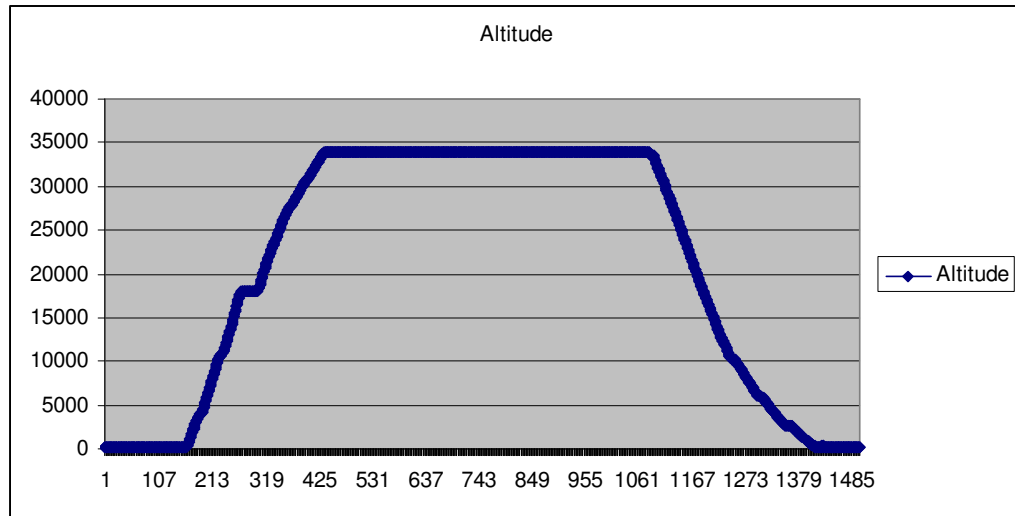
Şekil 4.1: Eğitimde Kullanılan Uçuşun İrtifa ve Eğitim Noktalarını Gösteren Profil



4.2 Eğitilen Ağın Kullanılması

Sinir ağının eğitimi bitirildikten ve test edildikten sonra farklı bir uçuşun parametreleri girilerek oradan alınan değerlerle yakıt akışının (fuel flow) tahmini yapılır. Bu uçuş yoluna dair hava aracının kalkıştan önceki ilk ağırlığı, sonraki aşamalarda ağırlık, hız, irtifa ve sıcaklık bilgileri girilerek çıkış olarak yakıt akışını vermesi beklenir. Eğitimde de, test ve tahminde de kullanılan performans noktaları birer saniyelik aralıklardır. Alınan yakıt akış değerleri dakikada tüketilen libre miktarıdır. Aşağıdaki şekilde model geliştirildikten sonra yakıt tüketiminin tahmin edilmesi istenen uçuşun performans noktalarında bulunduğu irtifanın profili gösterilmektedir.

Şekil 4.2: Yakıt Tüketiminin Tahmininde Kullanılan Uçuşun İrtifa ve Performans Noktalarını Gösteren Profil



Bu girişlerle, sinir ağı programı aşağıdaki şekilde her bir performans noktasındaki yakıt tüketimini hesaplayacaktır.

1) Taksi süresinde tüketim ağırlıkla lineer olarak doğru orantılı olduğu için sinir ağına ihtiyaç yoktur. Yakıt yakımı ilk ağırlık ve taksi süresine bağlı olarak hesaplanabilir.

2) Kalkıştaki yakıt tüketimi sinir ağı ile tahmin edilebilir. Bu uçuş safhasındaki ilk ağırlık taksi bölümündeki hava aracının son ağırlığıdır.

3) Tırmanma safhasındaki yakıt tüketimi hesabı için yapay sinir ağı kullanımına ihtiyaç vardır. Tırmanma yakıtın en yüksek seviyede kullanıldığı safhadır. Uçağın belirli bir irtifada kendine yer edinip oraya tutunana kadar yüksek itki ile tırmanması gerekir. Gaz kolunun ileri itilmesi uçakta kullanılan yakıt hava karışımındaki yakıt

oranın artırılması manasına gelir. Bununla birlikte doğal olarak yakıt akışı (fuel flow) da yükselir.

4) Düz uçuş bölümündeki yakıt tüketimini hesaplamak için kullanılan teknik, tırmanma safhasındakine benzerdir.

5) Alçalma safhasındaki yakıt tüketim hesaplama prosedürü tırmanma safhasıyla aynı olduğundan burada tekrarlanmamaktadır.

6) Uçuşun iniş bölümündeki yakıt tüketim hesaplaması da kalkış fazı ile aynı olduğundan bu bölümde tekrarlanmamaktadır.

5. SONUÇLARIN DEĞERLENDİRİLMESİ

Bu bölüm sinir ağı ile oluşturulmuş yakıt tüketim modelinin sonuçlarını sunar. Bu projenin sonuçlarını, verilen istatistik analizleri ve grafiksel gösterimleri içerir. Yüksek by-pass oranlı turbofan tipi gaz türbinli motorlara sahip olan orta boy gövdeli Boeing 737-800 modeli hava aracı modelin eğitim ve testlerinde ayrıca yakıt tüketim tahminlerinde kullanılmıştır. Yapay sinir ağıyla oluşturulan modelin sonuçları, kara kutudan alınan farklı bir uçuşun gerçek performansları ile karşılaştırılacaktır. Bu bölümde, eğitim sonuçları, test sonuçları ve yapay sinir ağıyla oluşturulan modelin yakıt tüketim tahmin sonuçları bulunmaktadır.

5.1 Eğitim ve Test Sonuçları

Yapay sinir ağını eğitmenin amacı ağırlık matrisi ve bias vektör setleri oluşturmaktır. Eğitim veri setleri, test edilen hava aracının kara kutusundaki verilerin download edilmesiyle sağlanır. Yapay sinir ağı öğrenmesinde kullanılan farklı uçuş fazlarına ait eğitim verilerinin boyutları Tablo 5.1’de gösterilmiştir.

Tablo 5.1: Eğitim Data Setleri

Uçuş Fazı	Eğitim Noktası Sayısı
Take-off	126
Climb	285
Cruise	1870
Descent	472
Landing	45

Eğitimi yapılan uçuşun take-off fazının, eğitim sonuçlarına ait tablolar aşağıda gösterilmiştir. Her bir faz için ağ 5 defa eğitilmiş ve bu çalışmalar sonundaki raporlar verilmiştir.

Tablo 5.2: Take-off Fazı Eğitim Raporu 1

<i>All Runs</i>	<i>Training Minimum</i>	<i>Training Standard Deviation</i>
Average of Minimum MSEs	0,004311036 [a]	0,002150256 [b]
Average of Final MSEs	0,004384043 [c]	0,002202061 [d]

Tablo 5.3: Take-off Fazı Eğitim Raporu 2

Best Network	Training
Run #	1[e]
Epoch #	998[f]
Minimum MSE	0,001616904[g]
Final MSE	0,001617099[h]

[a] = 5 defa yapılan eğitim sonucundaki minimum hataların ortalaması

[b] = 5 defa yapılan eğitim sonucundaki minimum hatanın standart sapması

[c] = 5 defa yapılan eğitimlerin sonucundaki verilen en son hataların ortalaması

[d] = 5 defa yapılan eğitimlerin sonucunda elde edilen en son hataların standart sapması

[e] = Eğitimler esnasında en küçük minimum hatanın yakalandığı çalışma

[f] = Eğitimler esnasında en küçük minimum hatanın yakalandığı periyot

[g] = Eğitimler esnasında yakalanan en küçük minimum hata

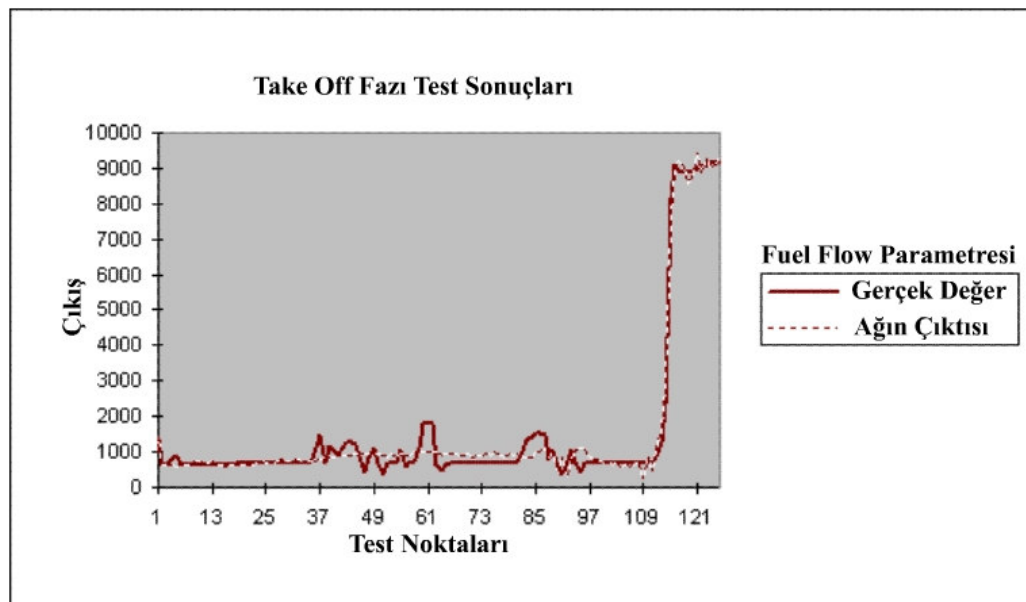
[h] = Eğitimler esnasında en küçük hatanın yakalandığı çalıştırmanın son periyotundaki minimum hata

Tablo 5.4: Take-off Fazı Parametrelerinin Korelasyon Analizi

	<i>Altitude</i>	<i>Airspeed</i>	<i>GrossWgt</i>	<i>FFlowSel-2</i>
Altitude	1			
Airspeed	0,649849	1		
GrossWgt	-0,34678	-0,55483	1	
FFlowSel-2	0,486759	0,81508	-0,65817	1

Yapılan korelasyon analizinin sonucu incelendiğinde en yakın ilişki yakıt tüketimi ile hız arasında vardır. Artan hızla birlikte yakıt tüketimi de artmaktadır.

Şekil 5.1: Take-off Fazı Test Grafiği



Tablo 5.5: Climb Fazı Eğitim Raporu 1

<i>All Runs</i>	<i>Training Minimum</i>	<i>Training Standard Deviation</i>
Average of Minimum MSEs	0,001029031[a]	0,000271251[b]
Average of Final MSEs	0,001031446[c]	0,000273556[d]

Tablo 5.6: Climb Fazı Eğitim Raporu 2

<i>Best Network</i>	<i>Training</i>
Run #	3[e]
Epoch #	170[f]
Minimum MSE	0,00061877[g]
Final MSE	0,000619314[h]

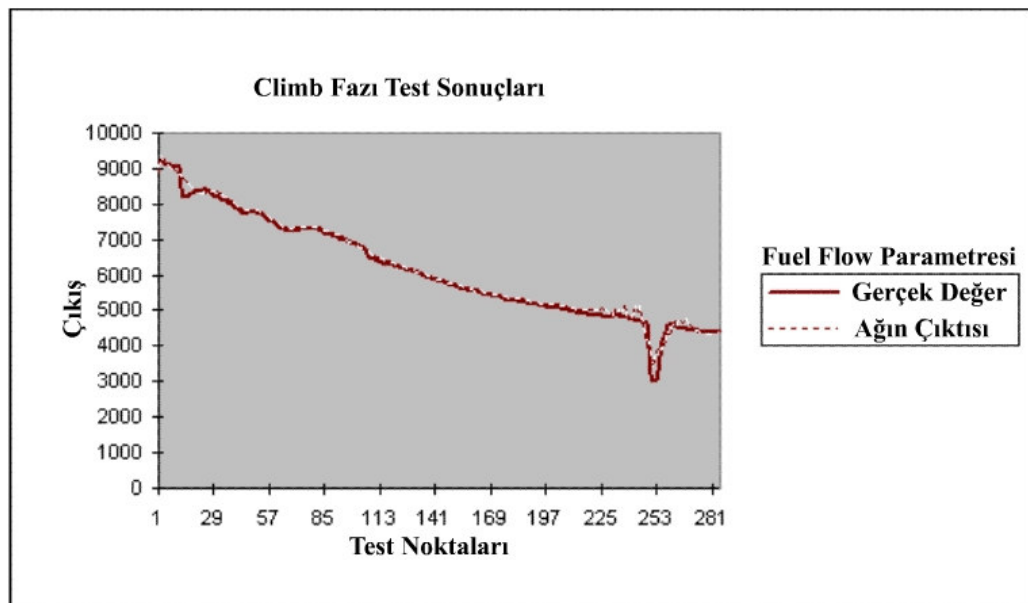
Bu tablolar içerisinde harfle ifade edilen kavramların açıklaması kalkış fazında verilmiştir. Onların aynısı burası içinde geçerlidir. Bundan dolayı onların tekrarı bu bölüm ve diğerlerinde yapılmayacaktır.

Tablo 5.7: Climb Fazı Parametrelerinin Korelasyon Analizi

	<i>Altitude</i>	<i>Mach</i>	<i>TAT</i>	<i>GrossWgt</i>	<i>FFlowSel-2</i>
Altitude	1				
Mach	0,97799	1			
TAT	-0,97719	-0,91337	1		
GrossWgt	-0,95439	-0,87629	0,991631	1	
FFlowSel-2	-0,98725	-0,96498	0,966246	0,939357	1

İstatistik analizine bakıldığında gerek negatif, gerek pozitif en yüksek korelasyon katsayılarının bu fazda olduğu görülmektedir. Ayrıca grafik ve tablolarda da görüldüğü üzere hatanın en düşük olduğu uçuş fazıdır.

Şekil 5.2: Climb Fazı Test Grafiği



Tablo 5.8: Cruise Fazı Eğitim Raporu 1

<i>All Runs</i>	<i>Training Minimum</i>	<i>Training Standard Deviation</i>
Average of Minimum MSEs	0,014284211[a]	0,004550894[b]
Average of Final MSEs	0,014467303[c]	0,004628155[d]

Tablo 5.9: Cruise Fazı Eğitim Raporu 2


<i>Best Network</i>	<i>Training</i>
Run #	4[e]
Epoch #	231[f]
Minimum MSE	0,008716212[g]
Final MSE	0,008725728[h]

Sinir ağının geliştirilmesi, yakıt tüketimi tahminin güvenilirliğini garanti etmek için eğitilmiş sinir ağındaki bilgilerin testini kapsar. Ağın güvenilirliği eğitilmiş ağın girişleri ne kadar iyi geliştirilebildiğine bağlıdır

Tablo 5.10: Cruise Fazı Parametrelerinin Korelasyon Analizi

	<i>Altitude</i>	<i>Mach</i>	<i>TAT</i>	<i>GrossWgt</i>	<i>FFlowSel-2</i>
Altitude	1				
Mach	0,188293	1			
TAT	-0,79995	0,089037	1		
GrossWgt	-0,21125	0,332133	0,497278	1	
FFlowSel-2	-0,11774	0,164393	0,241631	0,451533	1

Şekil 5.3: Cruise Fazı Test Grafiği



Tablo 5.11: Descent Fazı Eğitim Raporu 1

<i>All Runs</i>	<i>Training Minimum</i>	<i>Training Standard Deviation</i>
Average of Minimum MSEs	0,058128755[a]	0,0184658[b]
Average of Final MSEs	0,058546349[c]	0,018889472[d]

Tablo 5.12: Descent Fazı Eğitim Raporu 2


<i>Best Network</i>	<i>Training</i>
Run #	4[e]
Epoch #	710[f]
Minimum MSE	0,04471939[g]
Final MSE	0,04471939[h]

Tablo 5.13: Descent Fazı Parametrelerinin Korelasyon Analizi

	<i>Altitude</i>	<i>Mach</i>	<i>TAT</i>	<i>GrossWgt</i>	<i>FFlowSel-2</i>
Altitude	1				
Mach	0,94711	1			
TAT	-0,96844	-0,8418	1		
GrossWgt	0,976485	0,986501	-0,89575	1	
FFlowSel-2	-0,11574	-0,14297	0,07961	-0,12959	1

Şekil 5.1'den, Şekil 5.5'e kadar olan grafikler gerçek yakıt akışı ile geliştirilen yapay sinir ağı modellerinden sonuç olarak alınan yakıt akışlarının kıyaslanmasını gösterir.

Şekil 5.4: Descent Fazı Test Grafiği



Tablo 5.14: Landing Fazı Eğitim Raporu 1

<i>All Runs</i>	<i>Training Minimum</i>	<i>Training Standard Deviation</i>
Average of Minimum MSEs	0,154666335 <a>[a]	0,027907981 [b]
Average of Final MSEs	0,155952482 [c]	0,028898813 [d]

Tablo 5.15: Landing Fazı Eğitim Raporu 2

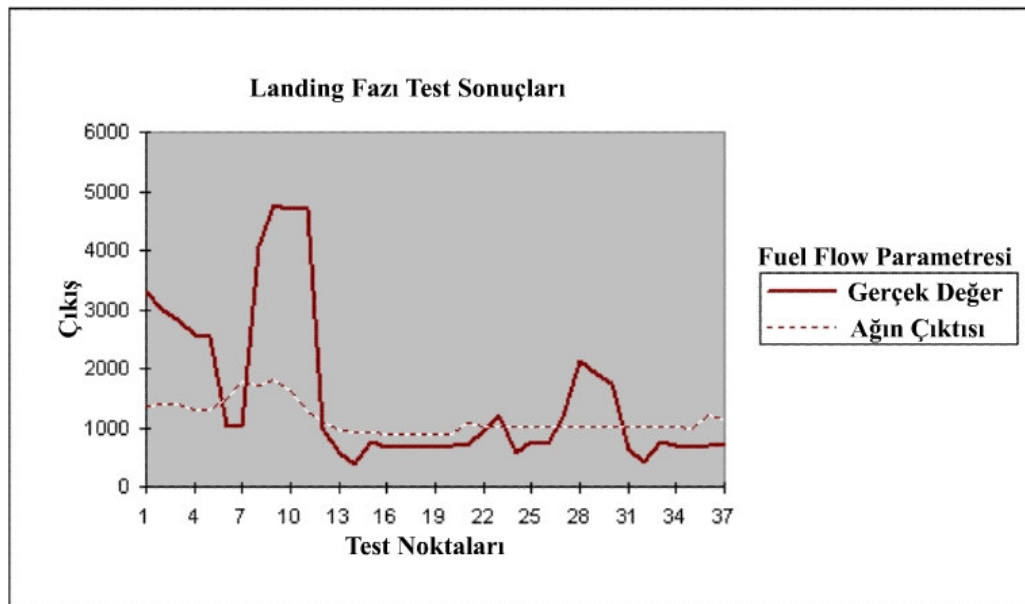
<i>Best Network</i>	<i>Training</i>
Run #	2 [e]
Epoch #	41 [f]
Minimum MSE	0,120141123 [g]
Final MSE	0,120141204 [h]

Tablo 5.16: Landing Fazı Parametrelerinin Korelasyon Analizi


	<i>Altitude</i>	<i>Airspeed</i>	<i>GrossWgt</i>	<i>FFlowSel-2</i>
Altitude	1			
Airspeed	0,416066	1		
GrossWgt	0,239347	0,582512	1	
FFlowSel-2	0,092138	0,559910	0,489757	1

Yakıt akışının en düzensiz olduğu uçuş safhası iniş bölümüdür. Yaklaşma esnasında hızı sabit tutmak ve irtifayı koruyarak piste istenilen açıda yaklaşmak hedef edinildiğinden gerekli görülen yerlerde anlık gaz verilmektedir. Bu da yakıt akışının anlık artması manasına gelir.

Şekil 5.5: Landing Fazı Test Grafiği



Şekil 5.6: Climb Fazı Altitude ve Fuel Flow Grafiği



Tırmanma (Climb) fazında uçak yükseldikçe hızı da artmaktadır. Artan hızla birlikte yakıtın arttığı öne sürülmüştür fakat şekildeki grafiğe bakıldığında uçak yükseldikçe yakıt tüketiminin düştüğü de görülmektedir. Ayrıca bu şekilden artan irtifanın yakıt tüketimini azalttığı gözlemlenebilmektedir. İkisinin arasında doğrusal olmayan bir ilişkinin varlığı şekilde görülmektedir.

Her uçuş fazı için korelasyon analiz tablosu da verilmiştir. Bu tablolar incelendiğinde birbirinden çok farklı değerler görülmektedir. Analizin sonucunda tahmin için kullanılan parametrelerin arasındaki ilişkinin genel olarak zayıf olduğu gözlemler arasındadır. Buradaki analizler gözönüne alınarak yakıt tüketiminin tahmin edilmesinin pek mümkün olmadığını, bu parametrelerin birbiri ile doğrusal olmayan bağıntıları olduğu istatistiksel analiz grafiklerinde de görülmektedir.

Her bir fazın ilk eğitim raporlarına göz atıldığında minimum MSE (Mean Square Error)'lerin ortalaması görülmektedir. Ayrıca yapılan tüm çalışmaların son periyotlarındaki MSE'lerin ortalaması da bu tablolarda mevcuttur. Bahsi geçen MSE'lerin her ikisinin de standart sapmaları yan tarafında görülmektedir.

Her bir uçuş fazı için ikinci eğitim raporlarında, yapılan tüm çalışmaların arasında en iyi MSE'in elde edildiği eğitimin numarası verilmiştir. Ayrıca elde edilen en iyi MSE değerinin hangi periyotta yakalandığı da burada gösterilmiştir. Yine bu raporda en iyi MSE değeri ve en iyi MSE değerinin yakalandığı çalıştırmanın son periyodundaki MSE değeri de gösterilmiştir.

Tablo 5.17: Uçuşun Tüm Fazlarının MSE ve Standart Sapma Tablosu

Uçuş Fazı	MSE	Standart Sapma
Take-off	0,004311036	0,002150256
Climb	0,001029031	0,000271251
Cruise	0,014284211	0,004550894
Descent	0,058128755	0,0184658
Landing	0,154666335	0,027907981


5.2 Sinir Ağı Yardımıyla Yakıt Tüketim Sonuçları

Bu araştırma projesinin son adımı her bir uçuş fazı için eğitilen yapay sinir ağı modellerine farklı bir uçuş göstererek yakıt tüketim tahminlerinin alınıp onların değerlendirmesini yapmaktır.

Bölüm 4'te programın detayları açıklandığından burada tekrarlanmayacaktır.


Girişler Boeing 737-800 uçağının kara kutusundan alınarak modelde kullanılmıştır. Başlangıçtaki brüt ağırlık 126705 pound olarak alınmıştır.

Şekil 5.7: Yakıt Tüketim Tahmini Yapılan Uçuşun Profili



Şekil 5.7 de görülen uçuş profilinde orjinden başlayan ve yatay eksene neredeyse paralel bir eğim gösteren doğru taksi ve take-off fazını oluşturmaktadır. Doğrunun pozitif bir eğimle yükselmeye başladığı yerde tırmanma fazı başlamaktadır. Şekil 5.8'de take-off fazı için yakıt tüketim tahmininin eğrisi görülmektedir.

Şekil 5.8: Take-off Fazı Yakıt Tüketim Tahmin Grafığı



Tablo 5.18: Take-off Fazı Yakıt Tüketimi Tahmin Raporu

Performance	FFlowSel-2
MSE[k]	114178,2805
NMSE[m]	0,300417229
MAE[n]	228,6460118
Min Abs Error[o]	2,303535128
Max Abs Error[p]	1741,501741
r[r]	0,848541872

[k] = Ortalama Kare Hatası (Mean Squared Error)

[m] = Normalleştirilmiş Ortalama Kare Hatası (Normalized Mean Squared Error)

[n] = Ortalama Mutlak Hata (Mean Absolute Error)

[o] = Minimum Mutlak Hata (Minimum Absolute Error)

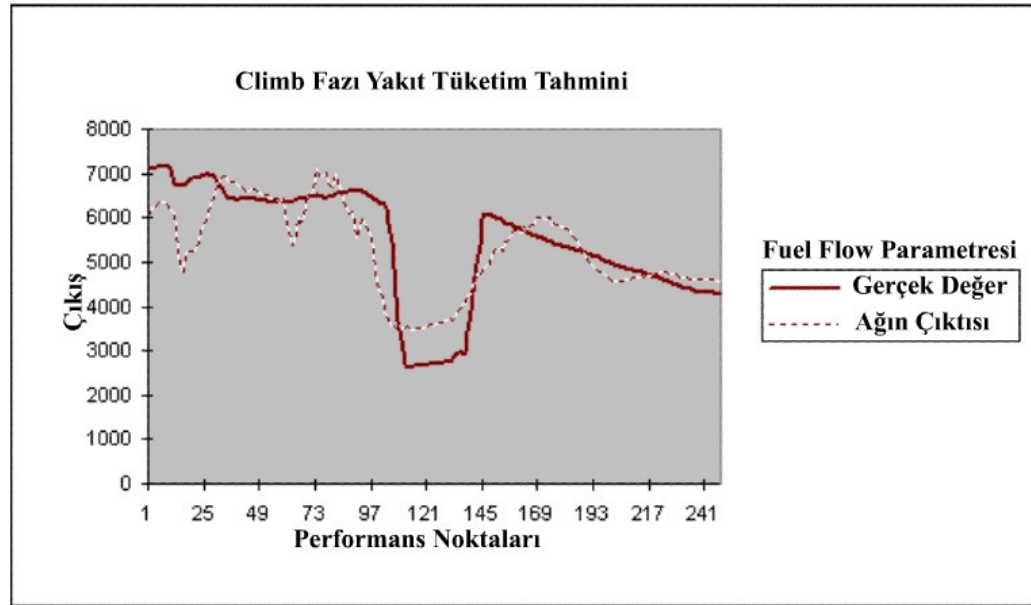
[p] = Maksimum Mutlak Hata (Maximum Absolute Error)

[r] = Doğrusal Korelasyon Katsayısı (Linear Correlation Coefficient)

Bu tablo içerisinde harfle ifade edilen kavramların açıklaması kalkış fazı tablosunun hemen altında verilmiştir. Onların aynısı bundan sonra çıkacak olan yakıt tüketim tahmin raporları içinde geçerlidir. Bundan dolayı yapılan açıklamaların tekrarı diğerlerinde yapılmayacaktır.

Şekil 5.8'de ki grafikte görüldüğü gibi gerçek yakıt akış eğrisi ile tahmini değerlerin oluşturduğu eğri birbiri ile neredeyse paralel bir görüntü vermektedir.


Şekil 5.9: Climb Fazı Yakıt Tüketim Tahmin Grafiği



Tablo 5.19: Climb Fazı Yakıt Tüketimi Tahmin Raporu

<i>Performance</i>	<i>FFlowSel-2</i>
MSE[k]	538976,8803
NMSE[m]	0,323541134
MAE[n]	555,6848192
Min Abs Error[o]	7,919146747
Max Abs Error[p]	2426,002789
r[r]	0,829866828

Şekil 5.10: Cruise Fazı Yakıt Tüketim Tahmin Grafiği




Tablo 5.20: Cruise Fazı Yakıt Tüketimi Tahmin Raporu

Performance	FFlowSel-2
MSE[k]	3296,51165
NMSE[m]	0,096196312
MAE[n]	33,35646018
Min Abs Error[o]	0,00365138
Max Abs Error[p]	533,7543538
r[r]	0,953241045

Şekil 5.9’da climb fazı yakıt tüketim tahmin grafiği ve Şekil 5.10’da da cruise fazı yakıt tüketim tahmin grafiği görülmektedir. Şekillere gözetildiğinde cruise fazında, climb fazına nazaran daha iyi sonuçlar alındığı görülmektedir. Zaten her ikisinin de korelasyon katsayısına bakıldığında climb fazı için 0,83 ve cruise fazı için 0,95 olduğu görülmektedir. İkisinin sonucu da pozitif ve yüksek ilişki olduğunu gösterse de cruise fazında ki hata oranının daha düşük olduğu bu analizlerden gözlemlenebilmektedir.

Şekil 5.11: Descent Fazı Yakıt Tüketim Tahmin Grafiği




Tablo 5.21: Descent Fazı Yakıt Tüketimi Tahmin Raporu

Performance	FFlowSel-2
MSE[k]	71459,75367
NMSE[m]	0,268270482
MAE[n]	179,4626542
Min Abs Error[o]	0,155373279
Max Abs Error[p]	1244,730101
r[r]	0,865040935

Şekil 5.11’de descent fazı yakıt tüketim tahmin grafiği ve Şekil 5.12’de de landing fazı yakıt tüketim tahmin grafiği görülmektedir. Bunlar uçuşun son iki safhasıdır. Buralarda alçalma ve yaklaşma yapıldığından yakıt akış oranlarında ani ve yüksek değerlerde artışlar olabilmektedir. Uçuşun bu bölümlerinin her ikisinin de korelasyon katsayısına bakılacak olursa descent fazı için 0,86 ve landing fazı için 0,83 olduğu görülmektedir.

Şekil 5.12: Landing Fazı Yakıt Tüketim Tahmin Grafiği



Tablo 5.22: Landing Fazı Yakıt Tüketimi Tahmin Raporu

Performance	FFlowSel-2
MSE[k]	282587,6132
NMSE[m]	0,323963284
MAE[n]	273,6021497
Min Abs Error[o]	0,405057186
Max Abs Error[p]	2240,207001
r[r]	0,831455362

Yakıt tüketim tahmini yapılan uçuşun tüm fazlarının tahmini ve gerçek değer arasındaki kıyaslanmanın yapıldığı grafikler yukarıda gösterilmektedir. Ayrıca bunların sonuçlarına ilişkin raporlarda ilgili tablolarda verilmektedir. Tablolardaki değerlerde tüm uçuş fazlarındaki korelasyon katsayısının 0,8 üzerinde olduğu görülmektedir.

Sonuç olarak bu bölümde yapay sinir ağı ile geliştirilmiş yakıt tüketim tahmini projesinin sonuçlarını gösteren grafik ve tablolar bulunmaktadır. Elde edilen verilerle gerçek değerler kıyaslandığında makul değerlerin bulunduğu görülmektedir.

Sonuçlar göstermektedir ki, çok fazla girdinin olduğu ve aralarındaki ilişkinin doğrusal olmadığı sistemlerde yapay sinir ağları verimli, güvenilir ve başarılı sonuçların elde edildiği bir tekniktir. Bu araştırma projesinin bazı sonuçları da bölüm 6'da ifade edilmektedir.

6. SONUÇLAR VE TAVSİYELER

6.1 Sonuçlar

Bu araştırmanın amacı; uçak kara kutusunda saklanan bilgilerin uçağın performansına katkı sağlayacağı düşüncesi ile bu parametrelerin kullanılacağı bir model kurabilmektir. Performans artırımı için pek çok seçilebilecek madde var iken yakıt tüketimi tercih edilerek enerji performans dengesinin incelenmesi ele alındı. Bu eksendeki genel amacın altında bulunan ve alt başlık denebilecek hedef ise; esnek, hesapsal olarak etkili ve hata oranının düşük olduğu, uçağın yakıt tüketim miktarını tahmin eden bir yapay sinir ağı modellenmesi idi ve araştırma hedefine ulaştı.

Hava aracı performans parametrelerine dayalı varolan yakıt tüketim modeli üzerinde durulmuştur ve bu modelin avantajları ve dezavantajları gözden geçirilmiştir. Sivil hava taşımacılığında kullanılan hava aracı kara kutusundan indirilen bilgiler kullanılarak örnek bir hava aracının yakıt tüketimi için yapay sinir ağı eğitilmiştir. Eğitilen modelle yakıt tüketim tahmini yapılmış ve bu tahminler gerçek uçuş sonuçları ile karşılaştırılmıştır.

Aşağıdaki sonuçlar elde edilmiştir:

1) Varolan yakıt tüketim modelinde kullanılan veriler uçuş el kitabında bulunan performans çizelgesinden alınmıştır. Buradaki değerler uçağın en iyi performans şartları altında çalıştığı düşünülerek hazırlanmıştır. Bu modelde kullanılan değerler ise doğrudan kara kutudan alındığı için gerçek uçuş parametreleridir ve çıkışlar da daha gerçekçidir.

2) Kara kutudan alınan bilgiler, bir hava aracının yakıt tüketimi bilgisini elde etmek için güvenilir bir kaynaktır.

3) Sinir ağıyla oluşturulan yakıt tüketim modelinden elde edilen sonuçlar gösterir ki, uygun eğitilmiş bir sinir ağı, hava aracının yakıt tüketimini hesaplamak için doğru ve verimli bir araçtır.

4) Yapay sinir ağı, yakıt tüketim uygulamalarında geçerli alternatif bir yol olarak görülmüştür.

6.2 Tavsiyeler

Bu proje zaman sınırlamasından dolayı sadece bir örnek hava aracı için ağ eğitilmiştir. Bu modelin tamamlanabilmesi için, yapay sinir ağı sivil havacılıktaki mevcut bütün hava araçlarından alınan bilgilerle eğitilmelidir. Ayrıca sinir ağı yakıt tüketim modeli için tek bir topoloji çalışması yapılmalıdır. Bu çalışmanın bütün olası hava araçlarına uyacağı yerinde bir topoloji seçilmelidir. Bu sebeple, ağ diğer bir hava aracı için eğitildiğinde ağırlıklar ve biasların veri tabanları kurulabilir. Kar amaçlı kurulan ticari havayollarının maliyetini minimuma indireyebilmesi için kendisine en avantajlı uçuş profilini çıkarması önemli bir mali tasarruftur.

Rekebatın en üst düzeyde olduğu günümüz havacılığında kaliteden ödün veremezsiniz. Sektörün yetişmiş eleman sayısı da kısıtlı olduğundan personel ücretlerinde de indirim gidemezsiniz. Rakiplerimize fark atabileceğiniz ve maliyetinin çok büyük bir kısmını oluşturan tek alan yakıttır. Bu model ile hava aracının izleyeceği rotayı, düz uçuş irtifasını, o irtifaya ne kadar sürede tırmanacağını ve seyrüsefer boyunca her uçuş fazı için optimum olan süratin tercih edilerek o hızda seyretmesi sağlanarak, bir kilonun dahi hesabının yapıldığı bir sektörde büyük maddi getiriler sağlanabilir. Hava aracında taşınan yakıtın da ağırlık oluşturduğu ve bu ağırlığın onlarca tonla ifade edildiği; artan ağırlıkla birlikte yakıt tüketiminin de arttığı düşünüldüğünde yüklenecek yakıtın en uygun değerde olması tercih edilir. Lufthansa Airlines, uçaklardaki koltukları hafifleterek yıllık 5 milyon litre yakıt tasarrufu elde ettiğini bildirmiştir (www.haber7.com). Bunun için havayolu taşımacılık şirketlerine filosundaki her model için uygun veri tabanına sahip bir yakıt tüketim modeli kullanılarak kar marjının artırılması tavsiye edilir.

Yapılacak önemli tavsiyelerden birisi de şu olmalıdır: burada, yakıt tüketimini birinci derecede ilgilendiren parametreler incelenmiş ve onlara dayalı bir model kurulmuştur. Oysa ki bu modelin girdilerini artırarak flap pozisyonları, iniş takımı pozisyonu, rüzgarın durumu vb. parametrelerle oluşan farklı koşulların denemesi yapılarak daha detaylı çalışan ve tahmindeki hata oranını düşüren bir modele ulaşmak hedef edinilmelidir.

Bu projeden sonraki hedef geliştirilen yapay sinir ağı modelini kullanarak bir uçağın belirlenen menzile giderken, kullanılacak minimum yakıt tüketimi için optimum uçuş parametrelerini belirleyen ve hava aracına o doğrultuda fayda sağlayan uçuş profilini veren bir program olmalıdır.

Bu projede, kara kutuda bulunan yüzlerce parametreden sadece altısı kullanılarak yapay sinir ağı ile bir çalışma yapılmıştır. Oradaki parametreler sadece uçak kazaları sonucunda tespit için kullanılmaktan çok uçak performans analizinde fayda sağlayacak şekilde kullanılmalıdır. Bu faydalardan yakıt tüketimi sadece bir başlık olabilir.

KAYNAKÇA

AYKAN,Rahmi&HACIYEV,Çingiz&ÇALIŞKAN, Fikret; “EKF ve Yapay Sinir Ağları ile Uçak Kanat Buzlanmalarının Tespiti ve Yeniden Şekillendirilebilir Kontrol”. İTÜ Dergisi, Cilt:5, Sayı:2, İstanbul, 2006.

Boeing 737-600/700/800/900 AMM(Aircraft Maintenance Manual), Part1. The Boeing Company, Seattle, 1997. (a)

Boeing 737-600/700/800/900 AMM(Aircraft Maintenance Manual), Part2. The Boeing Company, Seattle, 1997. (b)

BOLAT,Suna&KALENDERLİ,Özcan; “Levenberg-Marquardt Algoritması Kullanılan Yapay Sinir Ağı ile Elektrot Biçim Optimizasyonu”. İstanbul Teknik Üniversitesi, Elektrik- Elektronik Fakültesi, İstanbul, 2003.

COLLINS,Bela P.; “Estimation of Aircraft Fuel Consumption”. NASA Technical Reports Server, Washington, 1982.

EFE,Önder&KAYNAK,Okyay; “Yapay Sinir Ağları ve Uygulamaları”. Boğaziçi University Printhouse, İstanbul, 2004.

ELMAS,Çetin; “Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)”. Seçkin Yayıncılık, Ankara, 2003.

ERTAŞ,Sıtkı K.; “Meteoroloji Ders Notları”. DHMİ, Seyrüsefer Dairesi Başkanlığı, Ankara, 2004.

Model F1000 SSFDR CMM(Component Maintenance Manual). L3 Communacations Corp., Florida, 2004.

ÖZTEMEL,Ercan; “Yapay Sinir Ağları”. Papatya Yayıncılık, İstanbul, 2006.

SCHILLING,Glenn D.; “Modeling Aircraft Fuel Consumption With A Neural Network”. Virginia Polytechnic Institute and State University, Blacksburg, 1997.

ŞEN,Zekai; “Yapay Sinir Ağları İlkeleri”. Su Vakfı Yayınları, İstanbul, 2004.

TEC Aviation Training Manual, Module11. European Aviation Training Maintenance Conference, Luxembourg, 2006.

TRANI,Antonio A.; “A Neural Network Model to Estimate Aircraft Fuel Consumption”. AIAA 4th Aviation Technology, Integration and Operations(ATIO) Forum, Chicago, 2004.

VERBOS,P.; “The Roots of Backpropagation”. Wiley-Interscience Publications, 1994.

http://www.uted.org/dergi/1999/haziran/haziran_4.htm

<http://en.wikipedia.org/wiki/Airspeed>, a

<http://en.wikipedia.org/wiki/Altitude>, b

http://en.wikipedia.org/wiki/Total_air_temperature, c

http://en.wikipedia.org/wiki/Mach_number, d

<http://en.wikipedia.org/wiki/Taxiing>, e

<http://en.wikipedia.org/wiki/Takeoff>, f

<http://en.wikipedia.org/wiki/Climb>, g

http://en.wikipedia.org/wiki/Cruise_flight, h

http://en.wikipedia.org/wiki/Descent_of_an_aircraft, i

<http://en.wikipedia.org/wiki/Landing>, j

http://www.haber7.com/haber.php?haber_id=250362

ÖZGEÇMİŞ

Ad : Yaşar
Soyad : ALTUNTAŞ
Uyruđu : T.C.
Dođum Yeri : Ankara
Dođum Tarihi : 25.01.1981
Medeni Hali : Bekar
E-Mail : yasaraltuntas@gmail.com
Web : www.yasaraltuntas.com

Eđitim:

Yüksek Lisans: 2005-2007 Haliç Üniversitesi, Bilgisayar Mühendisliđi
Lisans : 1999-2004 Anadolu Üniversitesi, Havacılık Elektrik Elektronik
Lise : 1995-1998 Dikmen Teknik ve End. Mes. Lisesi, Elektronik

İş Tecrübesi:

2004- ... : THY A.O. Uçak Bakım Başkanlığı, Uçak Elektroniđi
2003- 2004 : Dizin Bilişim Ltd. Şti., Program-Grafik-Animasyon