



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**TURBOFAN UÇAK MOTORU VE RULMAN VERİLERİNDE KASKAT DERİN
ÖĞRENME MODELLERİYLE KESTİRİMCİ BAKIM**

DOKTORA TEZİ

Adem AVCI

Elektrik Elektronik Mühendisliği Anabilim Dalı

TEMMUZ 2023

T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**TURBOFAN UÇAK MOTORU VE RULMAN VERİLERİNDE KASKAT DERİN
ÖĞRENME MODELLERİYLE KESTİRİMCİ BAKIM**

DOKTORA TEZİ

**Adem AVCI
182082401
ORCID:**

Elektrik Elektronik Mühendisliği Anabilim Dalı

**Tez Danışmanı: Prof. Dr. Nurettin ACIR
ORCID:**

**Eş Danışman: Prof.Dr. Hakan GÜRKAN
ORCID:**

TEMMUZ 2023



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin aboneli olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Adem AVCI:

İmzası:





*Aileme ve doktora süresince sabrını ve desteğini
esirgemeyen sevgili eşime,*

ÖNSÖZ

Tez çalışmam boyunca sağlamış olduđu değerli katkıları için tez danışmanım Prof. Dr. Nurettin ACIR'a teşekkür ederim. Ayrıca tezimin son dönemlerinde destek olan ve yol gösteren değerli hocam Prof. Dr. Hakan GÜRKAN'a şükranlarımı sunarım.

Doktoramı yaptığım süre boyunca bana sabır gösteren ve desteğini hiçbir zaman esirgemeyen sevgili eşime sonsuz teşekkürlerimi sunarım. Bugüne kadar beni destekleyen aileme de teşekkürü bir borç bilirim.

Temmuz 2023

Adem AVCI

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vi
İÇİNDEKİLER	vii
KISALTMALAR	viii
ÇİZELGE LİSTESİ.....	x
ŞEKİL LİSTESİ.....	xi
ÖZET.....	xiii
SUMMARY	xv
1. GİRİŞ	17
1.1 Düzeltici Bakım.....	20
1.2 Önleyici Bakım	21
1.2.1 Planlı bakım	21
1.2.2 Koşullu bakım	22
1.2.3 Kestirimci bakım.....	23
2. METOT.....	41
2.1 Yapay Sinir Ağları	41
2.2 Çok Katmanlı Sinir Ağı.....	43
2.3 Evrimsel Sinir Ağları.....	45
2.3.1 Bir boyutlu evrimsel sinir ağları.....	48
2.4 Öz-Dikkat Katmanı	49
2.5 Dönüştürücü Katmanı	51
3. C-MAPSS UÇAK MOTORU VERİSİNDE KALAN FAYDALI ÖMÜR TAHMİNİ VE KESTİRİMCİ BAKIM UYGULAMASI.....	54
3.1 Veri Kümesinin Tanıtılması	54
3.2 Önışleme.....	57
3.3 Önerilen Model ve Sonuçları	64
3.4 Deneysel Sonuçların Analizi	70
3.5 Ablasyon Çalışmaları ve Sonuçları	78
3.6 Sonuçların Karşılaştırılması	81
4. FEMTO RULMAN VERİ SETİNDE KALAN FAYDALI ÖMÜR TAHMİNİ VE KESTİRİMCİ BAKIM UYGULAMASI.....	85
4.1 Veri Kümesi Tanıtılması	85
4.2 Önışleme.....	89
4.3 Önerilen Model	98
4.4 Deneysel Sonuçların Analizi	104
4.5 Sonuçların Karşılaştırılması	109
5. TARTIŞMA VE GELECEK ÇALIŞMALAR.....	111
KAYNAKLAR	116
ÖZGEÇMİŞ.....	125

KISALTMALAR

A2S	: Automatic Control and Micro-Mechatronic Systems
AA	: Ada Artırma
AESA	: Artık Evrişimsel Sinir Ağı
AÖM	: Aşırı Öğrenme Makinası
C-MAPSS	: Commercial Aero-Propulsion System Simulation
CSARN	: Cascade Self-Attention Residual Network
ÇKSA	: Çok Katmanlı Sinir Ağı
ÇYGYB	: Çift Yönlü Geçişli Yinelemeli Birim
ÇY-UKHA	: Çift Yönlü Uzun Kısa Hafıza Ağı
DAEA	: Derin Ayrılabilir Evrişim Ağı
DDİ	: Doğal Dil İşleme
DİA	: Derin İnanç Ağı
DÖ	: Derin Öğrenme
DR	: Doğrusal Regresyon
DSA	: Derin Sinir Ağı
DVM	: Destek Vektör Makinası
DVR	: Destek Vektör Regresyon
EAMBSO	: En Az Mutlak Büzülme ve Seçim Operatörü
EAR	: Ekstra Ağaç Regresyonu
EO	: Evrişimsel Otokodlayıcı
ESA	: Evrişimsel Sinir Ağı
FEMTO-ST	: Franche-Comté Electronics, Mechanics, Thermal Processing, Optics - Science and Technology
FSBT	: Frekans Spektrum Bölümleme Toplamı
ft	: feet
GA	: Gradyent Artırma
GAKA	: Gradyent Artırma Karar Ağacı
GGK	: Gaussian Gürültü Katmanı
GYB	: Geçişli Yinelemeli Birim
HAÖM	: Hiyerarşik Aşırı Öğrenme Makinası

Hz	: Hertz
HFD	: Hızlı Fourier Dönüşümü
HGAM	: Hafif Gradyent Artırma Makinası
HPC	: High Pressure Compressor
HPT	: High Pressure Turbine
İBSA	: İleri Beslemeli Sinir Ağı
KA	: Karar Ağaçları
KFÖ	: Kalan Faydalı Ömür
kHz	: KiloHertz
KKR	: K Komşuluk Regresyonu
KO	: K Ortalama
KOK	: Karekök Ortalama Kare
KOKH	: Karekök Ortalama Karesel Hata
KÖDAA	: Kaskad Öz-Dikkat Artık Ağı
KZP	: Kayan Zaman Penceresi
LPC	: Low Pressure Compressor
LPT	: Low Pressure Turbine
MÖ	: Makine Öğrenimi
N	: Newton
NASA	: National Aeronautics and Space Administration
OKH	: Ortalama Karesel Hata
ÖDK	: Öz-Dikkat Katmanı
PHM	: Prognostics and Health Management
PSO	: Parçacık Sürüsü Optimizasyonu
RO	: Rastgele Ormanlar
rpm	: rotate per minute
RVR	: Relevance Vektör Regresyon
SI'	: Sağlık İndeksi
SKO	: Sıralı Kuadratik Optimizasyonu
TBK	: Tam Bağlı Katman
TSA	: Tekrarlayan Sinir Ağı
UKHA	: Uzun Kısa Hafıza Ağı
YDG	: Yönlendirilmiş Döngüsüz Grafik
YSA	: Yapay Sinir Ağı
ZEBA	: Zamansal Evrişimsel Bellek Ağı

ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1 : C-MAPSS veri kümesi üzerinde makine öğrenimi algoritmaları ile yapılan çalışmalar.....	29
Çizelge 1.2 : C-MAPSS veri kümesi üzerinde ESA temelli yapılar ile yapılan çalışmalar.	31
Çizelge 1.3 : C-MAPSS veri kümesi üzerinde TSA temelli yapılar ile yapılan çalışmalar.	33
Çizelge 1.4 : C-MAPSS veri kümesi üzerinde hibrit yapılar ile yapılan çalışmalar.	37
Çizelge 2.1 : Aktivasyon fonksiyonları.	44
Çizelge 2.2 : Veri tipleri.	48
Çizelge 3.1 : C-MAPSS veri kümesinde motor kontrolleri için kullanılan giriş parametreleri [14].	55
Çizelge 3.2 : C-MAPSS veri kümesi oluşturulurken kullanılan sensörler [14].	55
Çizelge 3.3 : FD004 alt veri kümesi için altı farklı çalışma koşulu detayı.	56
Çizelge 3.4 : C-MAPSS veri kümesinin detayları.	56
Çizelge 3.5 : C-MAPSS veri kümesindeki sensörlere ait eğilim kategorisi.	60
Çizelge 3.6 : Önerilen CSARN modelinin detayları.	69
Çizelge 3.7 : Önerilen CSARN modeli ile elde edilen sonuçlar.	74
Çizelge 3.8 : Önerilen modellerin isimlendirilmesi.	79
Çizelge 3.9 : FD001 veri kümesinde model katmanlarının sonuçlara etkisi.	80
Çizelge 3.10 : FD002 veri kümesinde model katmanlarının sonuçlara etkisi.	80
Çizelge 3.11 : FD003 veri kümesinde model katmanlarının sonuçlara etkisi.	81
Çizelge 3.12 : FD004 veri kümesinde model katmanlarının sonuçlara etkisi.	81
Çizelge 3.13 : Önerilen model ile var olan yöntemlerin sonuçlarının KOKH metriği ile karşılaştırılması.	82
Çizelge 3.14 : Önerilen model ile var olan yöntemlerin sonuçlarının Skor metriği ile karşılaştırılması.	83
Çizelge 4.1 : Rulman veri kümesinin detayları.	87
Çizelge 4.2 : FEMTO-ST rulman veri kümesindeki tüm rulmanların çalışma ömürleri.	94
Çizelge 4.3 : Önerilen dönüştürücü temelli modelinin detayları.	104
Çizelge 4.4 : Önerilen model ile her rulman için elde edilen sonuçlar.	108
Çizelge 4.5 : Önerilen model ile var olan yöntemlerin sonuçlarının skor metriği ile karşılaştırılması.	110

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : Endüstriyel bakım çeşitleri.....	18
Şekil 1.2 : 30 farklı rulmanın zaman bazında bakımları [3].....	19
Şekil 1.3 : Zaman-olay kritikliği ile bakım maliyetlerine göre bakım türlerinin yeri [4].	20
Şekil 1.4 : Bakım maliyetleri ve bakıma kalan süre grafiği [2].....	23
Şekil 2.1 : Çok katmanlı sinir ağının temel yapısı.....	43
Şekil 2.2 : Aktivasyon fonksiyonların karşılaştırmalı grafiği.....	45
Şekil 2.3 : LeNet-5 evrimsel sinir ağı.	45
Şekil 2.4 : AlexNet derin evrimsel sinir ağı.....	46
Şekil 2.5 : İki boyutlu bir giriş için evrişim işlemi.	47
Şekil 2.6 : İki boyutlu bir giriş için maksimum havuzlama işlemi.....	48
Şekil 2.7 : Bir boyutlu bir giriş için bir boyutlu evrişimsel sinir ağı yapısı.	49
Şekil 2.8 : Dikkat katmanının genel yapısı.....	50
Şekil 2.9 : Çok başlı dikkat katmanı yapısı [93].....	52
Şekil 2.10 : Dönüştürücü ağının genel yapısı [93].	52
Şekil 3.1 : C-MAPSS veri kümesinde kullanılan motorların basitleştirilmiş diyagramı [95].	54
Şekil 3.2 : FD001 25'nolu motora ait çalışma koşullarının sensör verileri.	58
Şekil 3.3 : FD001 25'nolu motora ait çalışma koşullarının sensör verileri.	59
Şekil 3.4 : FD001 25'nolu motora ait normalize edilmiş sensör verilerindeki farklı eğilimli sensörler.	60
Şekil 3.5 : FD001 25'nolu motora ait normalize edilmiş sensör verileri.....	60
Şekil 3.6 : Bir uçak motoru verisinde kayan zaman pencere yönteminin gösterimi.	61
Şekil 3.7 : Doğrusal ve parçalı doğrusal bozulma modelleri.....	62
Şekil 3.8 : Skor ve KOKH değerlendirme metriklerinin karşılaştırılması.	63
Şekil 3.9 : KFÖ kestirim modelinde kullanılmak üzere önerilen öz-dikkat katmanı.....	66
Şekil 3.10 : KFÖ kestirim modelinde kullanılmak üzere önerilen resnet katmanı....	67
Şekil 3.11 : KFÖ kestirimi için önerilen model.....	68
Şekil 3.12 : Kayıp fonksiyonlarının karşılaştırılması.	70
Şekil 3.13 : FD001 test veri kümesindeki tüm motorların KFÖ kestirimi.	71
Şekil 3.14 : FD002 test veri kümesindeki tüm motorların KFÖ kestirimi.	72
Şekil 3.15 : FD003 test veri kümesindeki tüm motorların KFÖ kestirimi.	72
Şekil 3.16 : FD004 test veri kümesindeki tüm motorların KFÖ kestirimi.	73
Şekil 3.17 : FD001 test veri kümesindeki en iyi üç motorun kestirim grafiği.....	75
Şekil 3.18 : FD002 test veri kümesindeki en iyi üç motorun kestirim grafiği.....	76
Şekil 3.19 : FD003 test veri kümesindeki en iyi üç motorun kestirim grafiği.....	77
Şekil 3.20 : FD004 test veri kümesindeki en iyi üç motorun kestirim grafiği.....	78
Şekil 4.1 : FEMTO veri kümesinde kullanılan deney düzeneği [15].	85
Şekil 4.2 : FEMTO veri kümesindeki 1_1'nolu rulmanın sensör grafikleri.....	86

Şekil 4.3 : FEMTO eğitim veri kümesindeki tüm rulmanların ilk titreşim sensör grafikleri.	87
Şekil 4.4 : FEMTO-ST veri kümesinde titreşim verilerinin toplanma çizelgesi.	88
Şekil 4.5 : FEMTO test veri kümesindeki tüm rulmanların ilk titreşim sensör grafikleri.	89
Şekil 4.6 : Rulman1_1'e ait ilk titreşim sensörünün ilk 100 ms'lik kısmının zaman ve frekans uzayındaki temsili.	90
Şekil 4.7 : Rulman1_1'e ait ilk titreşim sensörünün son 100 ms'lik kısmının zaman ve frekans uzayındaki temsili.	90
Şekil 4.8 : Rulman1_2'nin zaman ve frekans uzayındaki temsilleri.	91
Şekil 4.9 : Rulman1_1'e ait ilk titreşim sensörünün ilk 100 ms'lik kısmının zaman ve mel frekans uzayındaki temsili.	93
Şekil 4.10 : Rulman1_1'e ait ilk titreşim sensörünün son 100 ms'lik kısmının zaman ve mel frekans uzayındaki temsili.	93
Şekil 4.11 : Rulman3_1 ve Rulman3_2'e ait bozulma modelleri.	95
Şekil 4.12 : Kayan zaman penceresi tekniğinin mel spektrogram üzerinde uygulanması.	96
Şekil 4.13 : Yarışma için oluşturulmuş değerlendirme metriği.	98
Şekil 4.14 : Önerilen öz-dikkat katmanı.	99
Şekil 4.15 : Önerilen çok başlı dikkat katmanı.	100
Şekil 4.16 : Önerilen ileri beslemeli sinir ağı.	101
Şekil 4.17 : Önerilen dönüştürücü katmanı.	102
Şekil 4.18 : Rulman titreşim verileri için önerilen derin öğrenme yapısı.	103
Şekil 4.19 : Birinci çalışma koşulundaki test rulmanlarının KFÖ tahminleri.	106
Şekil 4.20 : İkinci çalışma koşulundaki test rulmanlarının KFÖ tahminleri.	107
Şekil 4.21 : Üçüncü çalışma koşulundaki test rulmanının KFÖ tahmini.	108

TURBOFAN UÇAK MOTORU VE RULMAN VERİLERİNDE KASKAT DERİN ÖĞRENME MODELLERİYLE KESTİRİMCİ BAKIM

ÖZET

Gelişen sensör teknolojisi ve Endüstri 4.0 devrimiyle beraber üretim hatlarından ve sistemlerin her bir adımından büyük miktarda veri toplanmaktadır. Elde edilen bu veriler hem kalite kestirimi hem de sistem ve ekipmanlarının bakım zamanlarının kestiriminde kullanılmaktadır. Endüstri 4.0 ile beraber bakım faaliyetleri de evrim geçirmiştir ve kestirimci bakım ile arızalar meydana gelmeden kestirilmesi üzerine çalışılmaktadır.

Bakım süreçlerini günümüzde hassas ürünlerin çokça olması ve üretimdeki güvenilirlik sebebiyle daha da önem kazanmıştır. Doğru zamanda yapılan bakım faaliyetleri hem kaliteyi artırmakta hem de bakım maliyetlerini düşürmektedir. Kestirimci bakım uygulamaları ile arızalar meydana gelmeden önce ve ancak gereksiz parça değişimini de önleyecek şekilde sistemlerin takibi yapılmaktadır. Ayrıca toplanan veriler ile yapılan bu çalışmalarda duraksama sürelerini azaltmak için veriler içerisinde arızanın kaynağı ve türünün de kestirimi yapılmakta ve maliyetleri daha da azaltılabilmektedir. Bu tez kapsamında sistem ve ekipmanlarından elde edilen veriler üzerinde kestirimci bakım kapsamında Kalan Faydalı Ömür çalışmaları yapılmıştır. Bu kestirim modellerinde makine öğreniminin bir alt dalı olan derin öğrenme yapıları kullanılmıştır.

Bu tez kapsamında Commercial Aero-Propulsion System Simulation uçak motoru veri kümesi ile rulman titreşim verileri üzerinde Kalan Faydalı Ömür kestirimi çalışılmıştır. Bu çalışmalarda veri odaklı bir model geliştirilmesi amaçlanmıştır. Derin öğrenme tabanlı kestirim modelleri sunulmuştur. Özellikle son yıllarda ön plana çıkan Öz-Dikkat Katmanı temelli yapılar önerilmiştir. Böylelikle hem sensör verilerinde hem de ihtiyaç duyulan özneliliklerde sonuca etki edecek noktalara odaklanması amaçlanmıştır.

Uçak motoru veri kümesinde Öz-Dikkat katmanı ve kısayol içeren katman yardımıyla daha hassas kestirimler yapan bir model geliştirilmiştir. Ayrıca bu kestirim problemi için asimetric bir kayıp fonksiyonu önerilmiştir. İçermiş olduğu dört farklı senaryo ve alt veri kümelerinde başarımları test edilmiş ve elde edilen başarılı sonuçlar raporlanmıştır. Önerilen model ile FD001, FD002, FD003, FD004 alt veri kümelerinde Karekök Ortalama Karesel Hata metriğinde sırasıyla 11.017, 23.14, 12.62, 26.39 değerleri elde edilmiştir. Bu problem kapsamında veri yarışmasında önerilen skor fonksiyonunda ise sırasıyla 157.19, 2490.09, 218.6, 3800.15 değerleri elde edilmiştir. Çalışma kapsamında önerilen modelin belirli katmanlarının sonuçlar üzerine olan etkisi de ayrıca incelenmiştir.

Rulman titreşim veri kümesinde son yıllarda kullanıldığı alanlarda üstün başarımlar veren Dönüştürücü yapısı baz alınarak yeni bir derin öğrenme modeli sunulmuştur. Bu veri kümesinde yüksek örnekleme frekansına sahip titreşim verileri

frekans uzayındaki barındırmış olduđu bilgi önişleme ile kullanılabilir hale getirilmiştir. Mel frekans uzayına getirilen veriler derin bir yapıya sahip model ile eğitilmiştir. Veri kümesinin önerildiđi veri yarışmasında kestirim modellerinin başarımlarının karşılaştırılması için yeni bir skor değerlendirme fonksiyonu öne sürülmüştür. Test rulmanları üzerinde elde edilen sonuçlar bu skor fonksiyonunda 0.433 deđerini vermiştir. Test veri kümesindeki her bir rulmanda elde edilen sonuçlar ve genel skor deđerleri literatürdeki diđer modellerle karşılaştırmalı olarak sunulmuş ve başarımdaki üstünlük belirtilmiştir.

Artan veri miktarı ve derin öğrenme tekniklerinin gelişmesi ile daha hassas Kalan Faydalı Ömür tahminleri yapılabilmektedir. Özellikle tahmin çalışmalarında yeni modellerin ortaya konması ve bu yapıların titreşim, uçak motorları gibi verilerde derin yapılarla uygulanması başarılı sonuçlar vermektedir. Bu yapıların sistemlere uygulanması daha güvenilir ve izlenebilir yapıların kurulmasının önünü açmıştır.

Anahtar kelimeler: Kestirimci Bakım, Kalan Faydalı Ömür, Öz-Dikkat, Dönüştürücü, Makine Öğrenmesi, Derin Öğrenme.

PREDICTIVE MAINTENANCE ON TURBOFAN AIRCRAFT ENGINE AND BEARING DATA WITH CASCADE DEEP LEARNING MODELS

SUMMARY

With the developing sensor technology and the Industry 4.0 revolution, a large amount of data is collected from each step of the production lines and systems. These obtained data are used for both quality estimation and estimation of maintenance times of systems and equipment. With Industry 4.0, maintenance activities have also evolved, and predictive maintenance is being worked on before malfunctions occur.

Maintenance processes have become more important today due to the high number of sensitive products and reliability in production. Maintenance activities performed at the right time both increase quality and reduce maintenance costs. With predictive maintenance applications, systems are monitored before failures occur and in a way to prevent unnecessary parts replacement. In addition, in these studies carried out with the collected data, the source and type of failure can be predicted within the data to reduce downtime, and costs can be further reduced. Within the scope of this thesis, Remaining Useful Life studies were carried out within the scope of predictive maintenance on the data obtained from systems and equipment. Deep learning structures, a sub-branch of machine learning, were used in these prediction models.

Within the scope of this thesis, the Remaining Useful Life estimation was studied on the Commercial Aero-Propulsion System Simulation aircraft engine dataset and bearing vibration data. In these studies, it is aimed to develop a data-driven model. Deep learning-based prediction models are presented. Self-Attention Layer-based structures, which have come to the forefront in recent years, are proposed. Thus, it is aimed to focus on the points that will affect the result both in sensor data and in the required attributes.

In the aircraft engine dataset, a model that makes more precise predictions with the help of the Self-Attention layer and the layer containing shortcuts has been developed. In addition, an asymmetric loss function is proposed for this prediction problem. The model is tested on four different scenarios and sub-datasets, and the successful results are reported. With the proposed model, 11.017, 23.14, 12.62, and 26.39 values were obtained in the Root Mean Squared Error of evaluation metric in FD001, FD002, FD003, and FD004 sub-datasets, respectively. In the score function proposed in the data competition within the scope of this problem, 157.19, 2490.09, 218.6, and 3800.15 values were obtained, respectively. Within the scope of the study, the effect of specific layers of the proposed model on the results was also analyzed.

In the bearing vibration dataset, a new deep learning model is presented based on the Transformer structure, which has given superior performance results in the fields where it has been used in recent years. In this dataset, vibration data with high sampling frequency is made available by preprocessing the information contained in the frequency domain. The data brought to the Mel frequency domain were trained with a

model with a deep structure. A new score evaluation function is proposed to compare the performance of the prediction models in the data competition where the dataset is proposed. The results obtained on the test bearings gave a value of 0.433 in this score function. The results obtained on each bearing in the test dataset and the overall score value are presented in comparison with other models in the literature, and the superiority in performance is indicated.

More accurate Remaining Useful Life predictions can be made with the increasing amount of data and the development of deep learning techniques. In particular, introducing new models in prediction studies and applying these structures with deep structures in data such as vibration and aircraft engines give successful results. Applying these structures to systems has paved the way for establishing more reliable and traceable structures.

Keywords: Predictive Maintenance, Remaining Useful Life, Self-Attention, Transformer, Machine Learning, Deep Learning.




1. GİRİŞ

Bakım bir makine, makinenin bir parçası veya makinelerden oluşan sistemler ile fabrika gibi bir bütünün işlevselliğini devam ettirebilmesi ile tekrar çalışabilir hale getirilmesi için yapılan tüm fiziksel veya fonksiyonel çalışmaların bütünü olarak tanımlanmaktadır [1]. Bakım işlevinin en önemli sebebi üzerinde çalışılan makine veya parçasının sağlık durumunun kendisi ve çevre parçaları için kritik öneme sahip olmasıdır. Bir parçanın bakımının yapılmaması durumunda parçanın bozularak bulunduğu sistem üzerinde yıkıcı sonuçları olabilmektedir. Ayrıca bakım ile kullanılan makinelerin veya üretim bantları gibi büyük çaplı sistemlerde maliyetlerin düşmesine yardımcı olmaktadır.

Bakım işlevinin yapılma zamanına göre bakım maliyetleri çeşitlilik gösterebilmektedir. Bu maliyetler ise bakım için gerekli işçilik maliyeti, değiştirilen parçaların maliyeti, arızaya yakın kalite düşüklüğünden kaynaklı maliyet ve bakım anında makinenin ve üretimin duraksamasından kaynaklanan maliyetlerden oluşmaktadır. Makine ve parçalarına doğru zamanda yapılan bakım ile kazalar engellenebilmekte ve makinenin kullanım ömrü uzatılarak maliyetler düşürülebilmektedir.

İnsanoğlu araçları üretip kullanmaya başladığından beri bakım işleri yapılmaktadır. Birinci sanayi devrimi ve öncesinde üretilen araçlar veya makineler arıza meydana gelene kadar kullanılmaktaydı. Arıza meydana geldiğinde ise ya bakımı yapılır ya da yenisi ile değiştirilerek kullanıma devam edilmekteydi. Bu yapılan bakım çalışması literatürdeki çalışmalarda düzeltici bakım çalışması olarak anılmaktadır [2]. Zaman ilerledikçe bakım çalışmalarına olan bakış değişim göstermiştir ve bakımın önemi gitgide artmıştır. Makine veya sistemler üzerindeki bakım çalışmaları analiz edilmiş ve iki ana başlıkta bakım çalışmaları toplanmıştır. Bu bakım çalışmaları düzeltici bakım ve önleyici bakım çalışmalarıdır. Ayrıca yapılan analizler ve gelişen teknoloji ile önleyici bakım çalışmaları da evrim geçirmiştir. Değişen bakım stratejileri koşul-bazlı bakım, planlı bakım ve kestirimci bakım çalışmaları olarak önleyici bakım stratejisinin altında yer almaktadır. Bu yapı Şekil 1.1 gösterilmektedir.



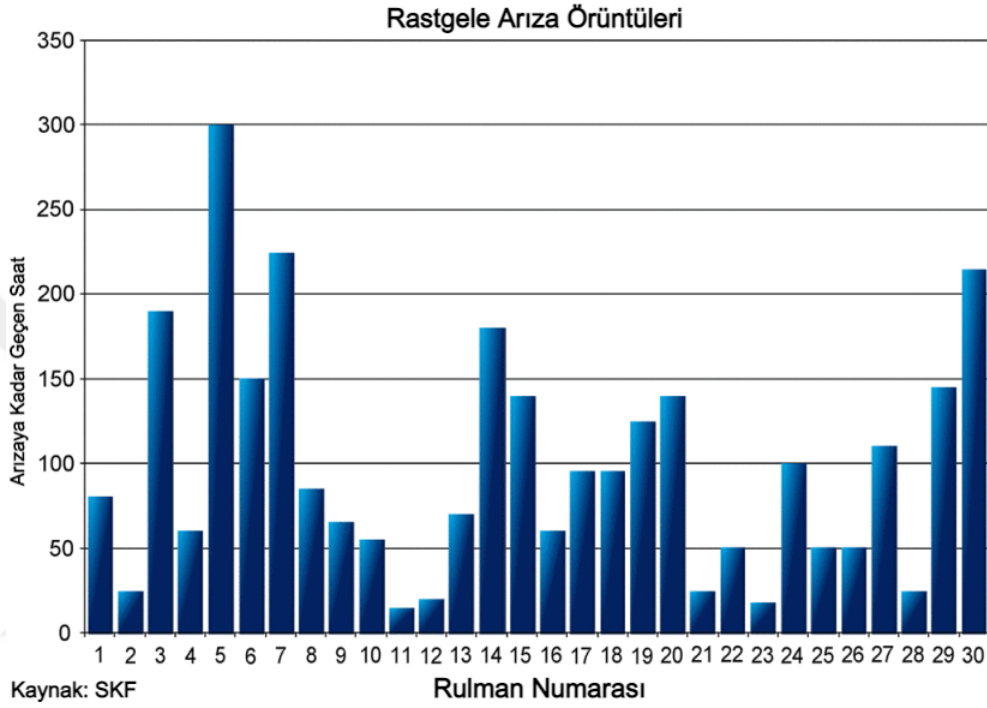
Şekil 1.1 : Endüstriyel bakım çeşitleri.

Önleyici bakım çalışmaları fabrikaların bakım maliyelerini azaltmak ve kullanılan makine ve sistemlerin ömrünü uzatmak için detaylıca tasarlanıp uygulanmaktadır. Koşullu bakım çalışmasında izlenen makinelerin daha önceki bakım tecrübelerinden faydalanarak sensör verilerinden bir veya fazlasının normal değerlerin dışında çıkmasıyla veya bir koşulu tetiklemesiyle bakım kararı alınmaktadır. Bu bakım kararı ile sistem arıza vermeden ve üretimde bekleme süresini arttırmadan bakım yapılarak maliyet düşürülmeye çalışılır. Ancak her makine için değiştirilmesi gereken parçalar için veya bakım yöntemi için gerekli ekipmanın bulundurulması ve depolanması gerekmektedir. Bakım için tetiklenen koşul zaman zaman gereksiz parça değişimine sebep olabilmektedir.

Planlı bakım faaliyetlerinde ise yine geçmiş bakım verilerine ve takvimine bakılarak arıza meydana gelmeden parçaların değiştirilmesine ve sistemlerin bakıma alınmasına karar verilir. Bu bakım çalışmasında en önemli iyileştirmeler fazladan parça depolama sorunun önüne geçmek, sistemler arızalanmadan ve üretim durmadan bakım faaliyetlerini gerçekleştirmek ve tüm sistemlerin bakım zamanlarını aynı zaman dilimine göre ayarlayarak tüm üretim hattının farklı zamanlarda durmasını engellemektir. Bu sebeple büyük üretim tesislerinde belli aralıklarla üretim durdurulur ve tüm sistemler bakıma alınmaktadır. Ancak bu bakım türünde de öngörülemeyen arızalar üretimi durdurabilmektedir. Üretimde kullanılan makineler ve parçaları ne kadar kalite kontrollerinden geçmiş olsa da vadedilen kullanım ömürlerini sunmayabilmektedir. Böyle arızalanan parçalar planlı bakımı zorlaştırmaktadır.

SKF mühendislik grubunun yapmış olduğu çalışmada döner makine elemanlarından rulmanların bir deney yardımı ile üzerlerine uygulanan stresle ömürlerini incelemiştir. 30 farklı rulman üzerinde yaptıkları çalışmada rulmanları arızaya kadar çalışma sürelerini kaydetmişler ve Şekil 1.2'de rulman ömürlerini göstermişlerdir [3]. Şekil incelendiğinde bazı rulmanların 15 saatlik çalışma süreleri

olurken bazılarının 300 saate kadar çıkabilmektedir. Bu çalışmanın diğer döner makinalara veya sistemdeki diğer parçalar içinde olabileceği varsayılabilir. Bu durumda planlı yaklaşımda bakım faaliyetleri en düşüğe göre yapılırsa gereksiz parça değişimine yol açabilir. Aksi durumda ortalama bir değer alınsa bile bu sefer beklenenden daha kısa sürede arızalanan rulman veya parçalar sistemde arızaya sebep olabilir ve üretimin durmasına sebep olabilmektedir.



Şekil 1.2 : 30 farklı rulmanın zaman bazında bakımları [3].

Önleyici bakım çalışmalarında gelişen sensör teknolojileri ve hesaplama gücüyle birlikte bakıma olan bakış daha proaktif bir yapıya bürünmüştür. Farklı zaman dilimlerinde arıza meydana gelen parçalarda planlı bakım sürecinin yürütülmesi zor olmaktadır. Uygun zamanlarda yapılmayan bakımlar sebebiyle üretilen ürünlerin kalitesi düşmekte ve tüm üretim sistemi üzerindeki genel maliyetler artmaktadır. Bu sebeple bu ve benzeri sorunların üstesinden gelmek için kestirimci bakım çalışmaları ön plana çıkmaktadır. Kestirimci bakımda ise sistemler üzerinde sensörler ile sürekli izleme yapılmakta ve arıza meydana gelmeden uyarı vererek bakım faaliyetleri gerçekleştirilmektedir. Böylelikle gereksiz parça değişiminin ve fazladan parça depolama işleminin önüne geçilmektedir. Ayrıca daha proaktif bir yapıya doğru çalışmalar yürütüldüğünde parçada meydana gelen arızanın teşhisi de yapılabilmektedir.

Düzeltilici bakım ve önleyici bakım çalışmaları Şekil 1.3'te bakım maliyetleri ve sistem güvenilirliği adına karşılaştırmaları yapılmıştır. Şekil 1.3'te tüm düzeltilici bakım ve önleyici bakım stratejileri zaman ve kullanılabilirliğe göre incelenmiştir [4]. Etkif bakım işlevi arıza meydana gelmeden çok kısa süre önce sistemleri durdurup bakıma alınması ve bakım süresinin minimum tutulması ile olmaktadır. Eğer çok geç bakıma alınırsa sistem arızadan sonrasına denk gelebilir ve daha büyük maliyetlere sebep olabilir. Çok erken yapılan bakımda ise sistem sık sık bakıma alınabileceği gibi gereksiz parça değişimlerine, fazla bakım ekipman ve ekiplerine gerek duyacağından bakım maliyetlerini arttıracaktır. Rastgele meydana gelebilecek arızalar dışında büyük koruma sağlasa bile maliyet konusunda sıkıntı oluşturabilmektedir. Grafikte de görüleceği üzere tüm bu değerlendirmelerden sonra kestirimci bakım çalışmaları hem arızaya olan yakınlığı hem maliyetlerdeki yeri için en etkil bakım daha yakın bir bakım faaliyettir.



Şekil 1.3 : Zaman-olay kritikliği ile bakım maliyetlerine göre bakım türlerinin yeri [4].

1.1 Düzeltilici Bakım

Düzeltilici bakım faaliyetleri bakım stratejileri içerisinde en basit olanı olarak yer almıştır. Bu bakım yöntemi insanlığın araçları ilk kullanmaya başladığı dönemden günümüze kadar devam etmektedir. Kullanıldığı yere göre diğer bakım türlerinden daha avantajlı olduğu yerler olabildiği gibi çok büyük risklere ve faaliyetlere de sebep olabilmektedir. Parçanın kendisinin ucuz ve değiştirilmesi kolay olan yerlerde düzeltilici bakım çalışmaları yapılmaktadır ve diğer yöntemlere göre daha avantajlıdır. Ancak geçmişten günümüze kadar incelenen bakım faaliyetlerinde hayati değere sahip parça veya makinelerin bakımları düzeltilici bakım yöntemleri ile yapılması yıkıcı sonuçlara sebep olduğu görülmüştür.

Bu bakım faaliyetlerinde sistemde veya parçalarında arıza meydana gelene kadar bakımın yapılmaması, arıza meydana geldiğinde basit bir yapı için değişimin

gerçekleştirilmesi ve karmaşık sistemlerde ise arızanın meydana geldiği parçanın değiştirilmesi prensibi ile çalışılmaktadır. Basit yapılara sahip parçalarda sensörler ile izleme yapmak yerine bu tür bir bakım faaliyeti uygulamak tüm üretim sistemi için daha az maliyet sağlamaktadır. Ancak artan yüksek teknolojik faaliyetler, karmaşık ve birçok parçadan oluşan sistemlerde düzeltici bakım faaliyetlerinin maliyeti artırdığı ve üretimi durdurduğu gözlenmiştir. Ayrıca rekabetin yoğun olduğu sektörlerde üretilen her ürünün yüksek kaliteli olması adına bu bakım faaliyetlerinin uygun olmadığı belirtilmiştir [5].

1.2 Önleyici Bakım

Önleyici bakım faaliyetleri gelişen teknoloji ve artan kompleks sistem yapısı ile üretim sistemlerinin ve fabrikaların temel bakım işlevi haline gelmiştir. Bu bakım faaliyetlerinin en temel, basit stratejisi planlı bakımdır. Sistemlerdeki parçaların gelişen sensör teknolojisinden gelen veriler ile sürekli olarak izlenebilmesini sağlamıştır. Böylelikle ekipmanlardan gelen sensör verilerine göre koşulların belirlendiği ve koşullu bakım faaliyetlerin oluşturulduğu bir yapı doğmuştur. Sensörlerden alınan verilerin artması ve gelişen makine öğrenimi yöntemleri ile kestirimci bakım faaliyetleri daha proaktif bir yapı olarak çok daha fazla ön plana çıkmaya başlamıştır. Gelecek bölümlerde bu önleyici bakım faaliyetlerinden detaylıca bahsedilecektir.

1.2.1 Planlı bakım

Planlı bakım faaliyetleri önceki bakımlardan edinilen bilgiler ve zaman kayıtlarına bakarak yeni bakım zamanının ayarlanması temeline dayanır. Periyodik bir yapısı vardır ve arıza meydana gelmeden bakımın gerçekleşmesi amaçlanmaktadır. Bu periyodik yapı ise daha önce yapılan bakımlarda ekipmanların ömürlerinin ve bakım işlevlerinin istatistiksel verileri alınarak belirlenmektedir. Ayrıca bu bakım türünde bakım sürecinde ekipmanların ömürlerini uzatmak adına yağlama, kontrol edilmesi, değiştirilmesi ve ürün kalitesinin değişmemesi için kalibre edilmesi gibi işlemler yapılmaktadır [2]. Böylelikle bakım için duraklatılan sistemde bakımı yapılan parça dışında diğer parçalarda incelenerek ömürleri uzatılmış ve bir sonraki bakım için aradaki süre uzatılmış olmaktadır. Her bakım anında arızalanan parçaların değişimi ve

diğer bakım işlemlerinin yapılması üretim sistemleri için bakım maliyetini artırmaktadır.

Kalitenin önem arz ettiği sektörlerde ve yüksek teknoloji kullanılan yerlerde bakım maliyeti daha da önem kazanmaktadır. Planlı bir bakım izlendiğinde genel itibari ile parça değişimi yapılmakta ve maliyeti arttırmaktadır. Ayrıca her parça bu takvim sürecinde belirlenen zamandan önce bozulmama durumu göstermemektedir. Çevre koşullarının etkisi veya parçanın üretici de hatalı üretilmesi sonucu daha erken meydana gelen bozulmalar da maliyeti katlamaktadır [6].

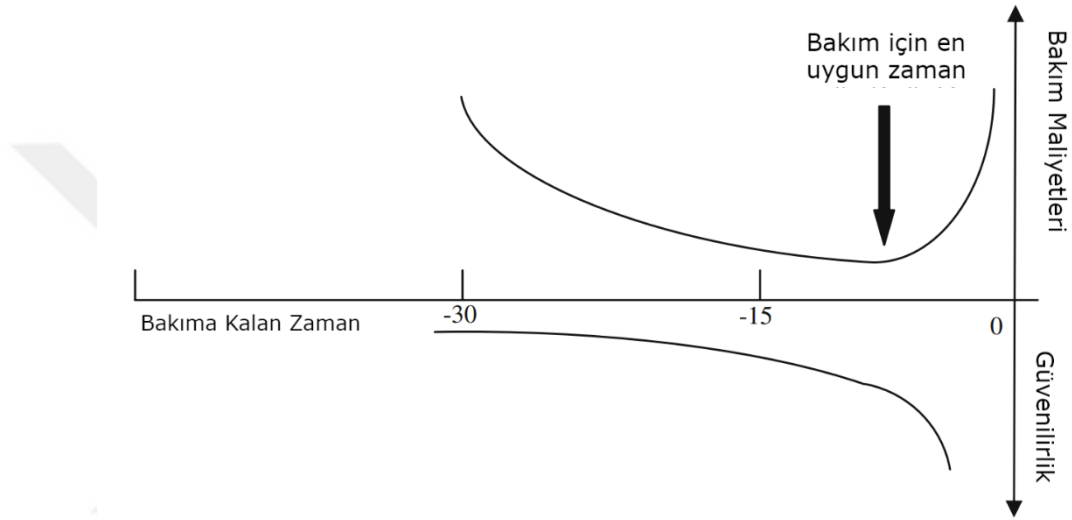
Bu bakım türünde takvim hazırlama işlevi alanında uzman planlamacılar, ekipman üreticilerin vermiş oldukları kullanım ömür programlarına göre hazırlanmakta ve geçmiş deneyimler ile bakım süreçleri göz önüne alınarak kısa süreli veya uzun süreli bakımlar planlanmaktadır. Rastgele meydana gelecek arızalar hazırlanan takvimin dışına çıkmaktadır ve son yıllarda daha proaktif bir yapı üzerine çalışılmaktadır.

1.2.2 Koşullu bakım

Koşullu bakım faaliyetleri, sistem ve bileşenlerini birçok sensör aracılığıyla takibi yapılarak durumundaki değişimine göre bakım kararı alınması temeline dayanmaktadır. Bu yapıda bakım yapılacak sistem üzerinde uzmanlaşmış ekiplere ihtiyaç duyulmaktadır. Bu ekipler sistemden gelen verileri inceleyip, sistemin davranışını analiz etmekte ve daha önceki tecrübelerle, bakım kayıtlarına göre normal davranışın dışına çıktığında bakıma alınmasını kararını vermektedir. Bu sensörlerden veriler periyodik olarak veya sürekli olarak alınmaktadır [2]. Toplanan veriler incelendikten sonra bir bakım örüntüsü oluşturulmakta ve sistem belirtilen örüntüye göre bakımları planlanmaktadır.

Koşullu bakım için sistemlerden sensör verileri ile o sistem üzerinde uzmanlaşmış ekiplere ihtiyaç duyulmaktadır. Elde edilen verileri ancak alanında uzman kişiler okuyup yorumlayabilmekte ve ona göre bakım kararını verebilmektedir. Bu bakım faaliyetini en basitiyle ele alırsak sensör verisi olmadan dahi anormal şekilde davranmaya başlayan ve bunun tespitini gözlemleyerek, dinleyerek yapan ekipler olabilmektedir. Bu sebeple önleyici bakım stratejilerinde daha basit ekipmanlar için az maliyetli bir çözüm olarak karşımıza çıkan bir stratejidir. Ancak alınan bu kararlar her zaman doğru olmadığı gibi bakım yapıldığında da gereksiz parça değişimi ve fazladan duraksama ile bakım maliyetlerini arttırabilmektedir.

Bir sistemin veya parçasının arızaya kadar olan süresi veya literatürdeki diğer ismi ile Kalan Faydalı Ömrü doğru şekilde tahmin edilmesi gerekmektedir. Bu bakım faaliyetlerinde uygun zamanda alınacak bakım kararı ile maliyetler minimize edilecektir. Ancak arızaya çok yakın olarak alınan kararlarda ise önerilen modellerin esnekliğinden veya hata payından dolayı bakım kararını yanlış alınabilmektedir. Şekil 1.4'te gösterildiği gibi arızaya kalan süreye göre bakım maliyeti ile güvenilirliği gösterilmektedir [2]. Bu grafikten de görüleceği üzere kullanılan modellerinde hata payını dikkate alarak uygun zamanda bakım kararının alınması gerekmektedir.



Şekil 1.4 : Bakım maliyetleri ve bakıma kalan süre grafiği [2].

Bu bakım türü planlı bakım faaliyetine göre daha kompleks ve iyi uygulandığında gereksiz maliyetleri düşürse de rastgele hatalara ve bilinmeyen arızalara göre karşı güvenilir olmamaktadır. Gelişen sensör teknolojisi artan veri miktarı ile derin öğrenme alanındaki gelişmeler bakım faaliyetlerini kestirimci bakıma doğru kaydırmıştır.

1.2.3 Kestirimci bakım

Geçmişten günümüze endüstride meydana gelen devrimler ile üretim hatlarında büyük değişimler olmuştur. Bu devrimler sonucunda bakıma olan bakış açısı değişmiş, güvenilirlik ve ürün kalitesinin daima sağlanması adına önleyici bakım stratejileri geliştirilmiştir. Üçüncü sanayi devrimi ile otomasyon sistemleri geliştirilmiş ve üretime entegre edilmeye başlanmıştır. Ayrıca gelişen sensör teknolojileri de bu entegrasyona dahil edilerek hem sistemlerden hem de üretimin birçok noktasından veriler alınmaya başlanmıştır. Bu veriler ürün kalitesini denetlediği gibi makinelerin çalışmalarını da izlemektedir.

Üçüncü sanayi devrimi ve sonrası ile üretim hatları gitgide daha karmaşık yapılar haline gelmiştir. Üretim hattı boyunca herhangi bir makine veya sisteminde meydana gelen arıza üretimin tamamını durdurabilmektedir. Bu sebeple bakım işlevinin hızla yapılmasını, doğru teşhisi ve onarımın halledilmesini gerektirmektedir. Önceki bölümlerde bahsedilen stratejilerle arızalar meydana gelmeden önüne geçilmeye çalışılmaktadır. Ancak beklenmedik arızalar kazalara veya beklenmeyen duraksamalara sebep olmaktadır. Bunun sonucunda da bakım maliyetleri artırmaktadır.

Gelişen sensör teknolojileri ve nesnelerin interneti ile daha fazla kaynaktan üretim hatları izlenmeye başlanmıştır. Kestirimci bakım çalışmaları da elde edilen bu veriler ışığında arıza meydana gelmeden makine veya parçasına ait arıza kestirimlerini sunmaktadır. Son yirmi yılda makine öğrenimi ve sinir ağları yapısında meydana gelen büyük atılımlar ile kestirimci bakım çalışmaları daha fazla ön plana çıkmaktadır. Kestirimci bakımın temelini sensörlerden gelen büyük veriler ile bu verileri işleyecek gelişmiş kestirim algoritmaları oluşturmaktadır [3].

Özellikle içerisinde yüksek teknoloji barındıran ve hayati öneme sahip makine veya teçhizatların bakımında erken tahmin ve doğru teşhis çok büyük bir öneme sahiptir [7]. Kestirimci bakım ile farklı stratejilerin geliştirilmesi bakımın erken tahmininin yapılmasını sağlamaktadır. Kestirimci bakım çalışmalarında farklı şekillerde ekipmanların takibi gerçekleştirilebilmektedir. Bunlar makineye ve izlenilen parçasına ait Kalan Faydalı Ömür (KFÖ) ile makinenin Sağlık İndeksinin (Sİ) takibinden oluşmaktadır. Kalan Faydalı Ömür literatürde bir bakım çalışmasından veya ilk kullanıma başlanıp arızanın meydana geldiği zamana kadar kalan süreyi ifade etmektedir [8]. Bu kestirimci bakım yaklaşımında KFÖ değeri sensör verileri anlık olarak geldiği sürece her gelen veri noktası ile yeni tahminler yapılması temeline dayanmaktadır. Bu yapı da tahmin edilen ömürler üzerinde çalışılan ekipmanın yapısına göre saniye, saat, gün olabildiği gibi döngü, atım gibi takip edilen durumlar da olabilmektedir. Aynı şekilde Sİ takibinde ise sistemin veya parçalarının başlangıçta sorunsuz çalıştığı ve zamanla arızaya gittiği varsayımına dayanmaktadır. Burada yapılan kestirimler ise 0 ile 1 arasında değişen makinenin durumunun nasıl olduğunu ifade eden değerlerdir. Bu iki farklı yaklaşım kullanılarak arızalar meydana gelmeden, ürün kalitesi düşmeden, güvenilirliği yüksek ve kullanılabilir bir bakım faaliyeti oluşturulabilmektedir [9]. Doğru şekilde ve önceden kestirilen arızalar ile uzun

ekipman ömrü, daha az arıza ve bununla gelebilen kazalar ile gereksiz parça değişiminin önüne geçilebilmektedir [10].

Kestirimci bakım çalışmaları gelişen makine öğrenimi algoritmaları ve geçen zamanla artan sensör verileri ile daha da ileri seviyede incelemelere evrilmektedir. Prognostik kavramı ile bu evrilmeye ortaya atılmış ve yapısı ile arızaya olan süre yani KFÖ kestirimi ile ekipman durum kontrolleri yanında arıza meydana geldiğinde arızanın kaynağının tespiti yapılmak istenmektedir. Bir makine üzerinden alınan sensör verileri ona ait birçok parçanın durumunu da içinde barındırmaktadır. Prognostik ile de herhangi bir arızaya ne kadar kaldığını hem de bu arızanın, eski arıza bilgilerine dayanarak, ne tür bir arıza olduğunu kestirmeye çalışılmaktadır. Böylelikle bakım faaliyetleri kestirimler ile optimize edilmiş olmaktadır. Ayrıca bakım anına geçildiğinde ise arızanın kaynağı erkenden teşhis edildiği için duraksamalar minimize edilmektedir [11].

Kestirimci bakım çalışmalarının doğru ve kesin bir şekilde gerçekleşebilmesi için bazı şartların sağlanması gerekmektedir. İncelenecek sistemin tamamı ya da bileşenlerinin belirlenmesi ve çalışma yapısına göre uygun sensörlerin kararlaştırılarak hassas ölçümlerin alınması gerekmektedir. Alınan verilerin uygun bir plan doğrultusunda depolanması ve arızalar meydana geldikçe hem arızanın çeşidi ve zamanı kaydedilerek hem de arızanın kök nedeni kaydedilerek verilerin doğru bir şekilde etiketlenmesi sağlanmalıdır. Ardından bu veriler gelişen makine öğrenimi ve derin öğrenme algoritmaları ile işlenerek karar mekanizmalarının oluşturulması gerekmektedir. Böylelikle bakım maliyetleri azalacak ve sistem güvenilirliği artacaktır [12].

Bunların yanı sıra kestirimci bakımın incelenecek sisteme uygulanmasının zorlukları da bulunmaktadır. Öncelikle incelenecek sistemden veri elde etmek zor olmaktadır. Hassas sensörlerin sisteme entegrasyonu verilerin doğru şekilde alınması ve senaryoya uygun şekilde etiketlenmesi gibi zorluklar bulunmaktadır. Ayrıca elde edilen sensör verilerin büyük bir üretim tesisinde takibi, depolanması ve işlemeye uygun hale getirilmesi gerekmektedir. Bazı işletmelerin ya bu sistemi idare edecek altyapıları ya da bunları kontrol edebilecek ekipleri bulunmamaktadır. Bunların yanında bir bakım kestirim modeli geliştirilmiş ve sisteme entegre edilmiş olsa bile rastgele meydana gelebilecek arızalar az da olsa tehlike arz etmektedir. Bu sebeple toplanacak etiketli verilerin sayısının fazla olması ve farklı tür arızalardan oluşması gerekmektedir [13].

Kestirimci bakım çalışmalarında kullanılmak üzere literatürde farklı veri kümeleri üretilmiştir. Üretilen veri kümeleri gerçek hayattaki sistemlerin benzetim programlarında modellenmesi ve bu modellerden verilerin alınması ile oluşturulabildiği gibi laboratuvar ortamında deneysel çalışmalar ile de veriler toplanabilmektedir. Ayrıca direk üretim hatlarından veya çalışan sistemler üzerinden veriler toplanarak da KFÖ çalışmaları yapılmaktadır. Kestirimci bakım için tehlikeli veya maliyetli olan sistemlerde veri kümelerinin hazırlanması benzetim ortamında modellemeler üzerinden olmaktadır.

Literatürde sıklıkla kullanılan ve bozulma modellerin test edildiği standart veri kümeleri mevcuttur. Bu veri kümeleri açık kaynak olup farklı kurumlar tarafından farklı senaryolarda oluşturulmuştur. Veri kümelerinde kullanılan sistemler rulmanlar, uçak motor verileri, bataryalar ve dişli çarkları gibi döner makina elemanlarından oluşmaktadır. Açık kaynak veri kümelerinden National Aeronautics and Space Administration (NASA) Ames Araştırma Laboratuvarı tarafından oluşturulan Commercial Aero-Propulsion System Simulation (C-MAPSS) veri kümesi uçak motorlarının modellenmesi ve arızaların tahmini üzerine oluşturulmuştur [14]. Bu veri kümesi üzerinde KFÖ çalışmaları literatürde yapılmaktadır. Bununla birlikte NASA'nın Akıllı Bakım Sistemleri Merkezi tarafından Prognostics and Health Management (PHM) 2012 konferansındaki veri yarışmasında KFÖ tahmini için rulman veri kümesi sağlanmıştır [15]. Bu veri kümesi rulmanların çalışma süreleri boyunca titreşim verilerinin izleyen sensör verilerinden oluşmaktadır. Literatürde kurum ve üniversiteler iş birliğinde birçok rulman veri kümesi de bulunmaktadır. Case Western Reserve University (CWRU) ve Paderborn University tarafından hazırlanan Paderborn rulman veri kümeleri de mevcuttur ve bunlar hem teşhis hem de prognostik çalışmalarında kullanılmaktadır [16-19]. Ayrıca yine NASA iş birliğinde freze üzerinde KFÖ tahmini için veri kümesi hazırlanmıştır [20].

Bu tez çalışmasında kestirimci bakım üzerinde çalışmalar yapılmıştır. Kestirimci bakımın alt inceleme alanlarından olan KFÖ kestirimi üzerine durulmuştur. Bu alanda gerçek zamanlı üretim sistemlerinden verilerin elde edilmesi zorluğundan dolayı KFÖ için literatürde çalışılan veri kümeleri üzerinde modeller geliştirilmiştir. Bu tez çalışmasında uçak motoru verileri ile rulman döner makine elemanı veri kümesi üzerinde çalışmalar yürütülmüştür. Gelişen derin öğrenme modelleri ve farklı önışleme teknikleri kullanılarak KFÖ kestirimleri yapılmıştır. Bu çalışma kapsamında

PHM2008 konferansları için hazırlanmış C-MAPSS uçak motoru veri kümesi ile PHM2012 konferansına hazırlanmış rulman veri kümesi kullanılmıştır. Öncelikle uçak motoru veri kümesi üzerinde literatürde yapılan çalışmalardan ve ardından rulman veri kümesi üzerinde yapılan çalışmalar detaylıca incelenecektir.

Literatürde yapılan KFÖ kestirim çalışmaları farklı yaklaşımlara sahiptir. C-MAPSS veri kümesi üzerinde modelleme temelli, veri temelli veya hibrit yaklaşımlar olmak üzere üç farklı türde çalışmalar mevcuttur [21]. Modelleme temelli yaklaşım çalışmalarında, üzerinde çalışılan sistemin fiziksel veya matematiksel modelleri çıkartılarak KFÖ kestirimleri yapılmaktadır. Bu kısımda istatistiksel yaklaşımlar, matematiksel modeller ve benzetimler kullanılmaktadır [22]. Modelleme çalışmalarında çatlak ilerlemesi için Paris-Erdoğan modeli kullanılmış ve KFÖ kestirimleri için üstel model ile parçacık süzgeç metodu kullanılmıştır [23-25]. Günümüzde kullanılan sistemler çok fazla ekipmandan oluşmakta ve karmaşık yapılara sahip olmaktadır. Sistem karmaşıklığı arttıkça matematiksel modellemesini oluşturmak zorlaşmaktadır. Ayrıca sistem içerisindeki her bir ekipmanın çalışma ömürlerinin farklı olması, arızaya yaklaştıkça diğer parçaların bozulmasını hızlandırması sebebiyle KFÖ kestirimleri zorlaşmaktadır. Yapılan sistem modelleri ve bunlar için geliştirilen KFÖ kestirimleri çevre koşullarının ve çalışma modlarının değişmesine iyi tepki veremediğinden KFÖ kestirimleri yeterli olamamaktadır.

Kestirimci bakım çalışmalarında model tabanlı yaklaşımların yeterli gelmediği problemlerde veri temelli yaklaşımlarla desteklenerek veya birlikte kullanılarak hibrit yaklaşımlar kullanılmıştır [26]. Model tabanlı yaklaşımlarda sistem veya parçaları modellenerek bozulma modelleri oluşturulsa da çevre koşullarına, çalışma koşullarına ve gürültüye karşı gürbüz çalışmamaktadır. Hibrit modellerde veri temelli yaklaşımla birlikte model tabanlı yaklaşım kullanılmış, gürültülü verilere ve çalışma koşullarına uyum sağlaması hedeflenmiştir [27].

KFÖ kestirim çalışmalarında makine öğrenimi ve derin öğrenme alanlarında meydana gelen gelişmeler ile veri temelli yaklaşımlar üzerinde çalışmalar artmıştır. Elde edilen sonuçlar model tabanlı ve hibrit yaklaşımlara göre çok daha iyi sonuçlar verebilmektedir. C-MAPSS veri kümesi yayınlandığı yarışma ve sonrası üç farklı yaklaşım ile çalışmalar yapılmıştır. Yayınlanmasından bu yana makine öğrenimi ve derin öğrenme çalışmaları ile özellikle gürültülü olan veride çok daha iyi sonuçlar elde edilmiştir.

Babu ve ark. yaptıkları çalışmada C-MAPSS veri kümesi üzerinde ilk kez ESA yapısı ile kestirim modeli önermişler ve elde ettikleri sonuçları makine öğrenimi yöntemleri ile karşılaştırmışlardır. Bu çalışma kapsamında Destek Vektör Regresyon (DVR), Relevance Vektör Regresyonu (RVR) ve ÇKSA, makine öğrenimi teknikleri ile de kestirimler yapılmıştır. Bu kestirimler sırasında veriler 15 çevrim uzunluklu bir Kayan Zaman Penceresine (KZP) göre hazırlanmış ve sonuçlar elde edilmiştir. Tüm alt veri kümeleri üzerinde elde edilen sonuçlar karşılaştırmalı olarak sunulmuştur [28].

Zhang ve ark. C-MAPSS üzerinde KFÖ kestiriminde yeni bir derin öğrenme algoritması sunmuşlardır. Bu çalışma içerisinde makine öğrenimi algoritmaları ve uyarlanabilir algoritmalarda uygulayarak karşılaştırmalı sonuçlar elde etmişlerdir. Çalışmalarında farklı uzunluklarda KZP'leri kullanmışlardır. Ayrıca 30 çevrim uzunluklu zaman penceresi uygulanmış ve ÇKSA, Aşırı Öğrenme Makinesi (AÖM), Hiyerarşik AÖM (HAÖM), En Az Mutlak Büzülme ve Seçim Operatörü (EAMBSO), Ekstra Ağaç Regresyonu (EAR), K Komşuluk Regresyonu (KKR), Gradyent Artırma (GA), Rastgele Ormanlar (RO) ve DVM algoritmaları ile sonuçlar elde edilmiştir [29].

Li ve ark. yapmış oldukları çalışmada C-MAPSS veri kümesinin FD001 alt veri kümesinde makine öğrenimi algoritması önermişlerdir. Bu çalışma kapsamında Hafif Gradyent Artırma Makinesi (HGAM) algoritması kullanmışlardır. Verilere 30 çevrim uzunluklu zaman penceresi uygulamışlar ve 0-1 arasında normalize etmişlerdir. Elde ettikleri sonuçları karşılaştırmalı olarak sunmuşlardır [30].

Mathew ve ark. yaptıkları çalışmada C-MAPSS veri kümesinin tüm alt veri kümelerinde Doğrusal Regresyon (DR), Karar Ağaçları (KA), DVM, RO, KKR, K Ortalama (KO), GA, Ada Artırma (AA), Derin Öğrenme (DÖ) ve Anova olma üzere on farklı makine öğrenimi algoritması kullanarak karşılaştırmıştır. Bu çalışmada elde edilen sonuçlar sadece Kök Ortalama Karesel Hata (KOKH) hesaplanarak yapılmıştır [31].

Wu ve ark. yapmış oldukları çalışmada C-MAPSS veri kümesinin en karmaşık alt veri kümesi FD004'te toplu öğrenme algoritmasını kullanarak kestirim yapmışlardır. Bu çalışma kapsamında farklı temel öğrenme algoritmaları seçilmiştir. Ayrıca 21, 11, 7 ve 3 adet sensör seçilerek veri kümesi tekrar tasarlanmış ve algoritmalar eğitilerek sonuçlar alınmıştır. Temel öğrenme algoritmalarının hiper-parametreleri Parçacık Sürüsü Optimizasyonu (PSO) ve Sıralı Kuadratik Optimizasyon (SKO) ile optimize

edilmişlerdir. Bu temel algoritmalar veri kümesi ile eğitilerek sonuçlar elde edilmiş ve karşılaştırmalı olarak sunulmuştur [32].

Lim ve ark. yaptıkları çalışmada C-MAPSS veri kümesindeki 21 adet sensörün 14'ünü kullanmışlar ve verilerini -1 ile 1 arasına normalize etmişlerdir. Çalışmalarında kayan zaman pencere tekniğini farklı boyutlu pencereler ile YSA modelini kullanarak test etmişlerdir. Böylelikle zaman penceresi boyutunun sonuçlara olan etkisi incelenmiştir [33].

Literatürde C-MAPSS veri kümesi üzerinde yapılan ve makine öğrenimi algoritmalarını kullanan çalışmalar Çizelge 3.5'te gösterilmiştir. Bazı çalışmalarda veri önışlemede kayan zaman pencere yöntemi ve normalizasyon işlemleri ya kullanılmamış ya da bildirilmemiştir. Karşılaştırmalı sonuçlar için tek bir çalışma içerisinde birçok algoritma kullanılmış ve sunulmuştur.

Çizelge 1.1 : C-MAPSS veri kümesi üzerinde makine öğrenimi algoritmaları ile yapılan çalışmalar.

Kullanılan Yöntemler	KZP (çevrim)	Normalizasyon	Referans
DVR, RVR, ÇKSA	15	z-skor	[28]
ÇKSA, AÖM, HAÖM, EAMBSO, EAR, KKR, GA, RO, DVM	30	[-1,1]	[29]
ÇKSA	30	[-1,1]	[33]
HGAM	30	[0-1]	[30]
DR, KA, DVM, RO, KEYK, KO, GA, AA, DÖ, Anova	-	-	[31]
Toplu Öğrenme	-	-	[32]

Babu ve ark. yapmış oldukları çalışmada C-MAPSS veri kümesinde ilk kez ESA yapısını çalışmalarında kullanmışlardır. Bu çalışmada uçak motorlarına ait çalışma koşulları 6 farklı öznitelik olarak veri kümesine dahil edilmiştir. Ardından veriler z-skor normalizasyon ile normalize edilmiş ve 15 boyutlu zaman penceresi ile önışleme tabi tutulmuştur. Elde edilen sonuçlar diğer makine öğrenimi algoritmaları ile karşılaştırmalı olarak sunulmuştur [28].

Li ve ark. kestirim çalışmalarında zamanla değişen sensör değerlerini kullanmışlar ve kayan zaman pencere yöntemi ile C-MAPSS veri kümesini hazırlamışlardır. Çalışmaları kapsamında zamanla değişen 14 adet sensör öznitelik olarak kullanılmış ve veriler -1 ile 1 aralığında normalize edilmiştir. Önermiş oldukları 2 boyutlu ESA modelinde zaman boyutunda süzgeçler kullanılmış ve ezberlemeyi önlemek için

seyreltme mekanizması kullanılmıştır. Elde edilen sonuçlar hem kendi geliştirdikleri diğer DSA yapısı ile hem de literatürdeki diğer sonuçlar ile karşılaştırılmış ve sunulmuştur [21].

Jayasinghe ve ark. yapmış oldukları çalışmada önermiş oldukları Zamansal Evrişimsel Bellek Ağı (ZEBA) ile KFÖ kestirimi yapmışlardır. Yapılan çalışmada veri arttırımına gidilmiştir. Ardından veriler z-skor normalizasyon ile normalize edilmiş ve kayan zaman penceresi kullanılmamıştır. Önerilen modelde 1B ESA ile Uzun Kısa Hafıza Ağı (UKHA) ardı ardına kullanılmıştır. Elde edilen sonuçlar karşılaştırmalı olarak raporlanmıştır [34].

Wen ve ark. literatürde C-MAPSS veri kümesi üzerinde ilk kez Artık ESA (AESA) yapısını kullanmışlardır. Önerdikleri Artık Evrişim bloklarda kısayol yapısını kullanarak kaybolan/patl原因an gradiyent probleminin üstesinden gelmeye çalışmışlardır. Çalışma kapsamında kullanılan Artık Evrişim bloklarını sayısının sonuçlara olan etkisi incelenmiş ve verilerin karmaşıklığına göre farklı sonuçlar ortaya çıkmıştır. Derinlik arttığında daha karmaşık alt veri kümelerinde ezber olmakta ve test veri kümesinde sonuçlar kötüleşirken FD001 gibi daha basit koşullu veri kümesinde daha iyi sonuçlar üretebildiği gözlenmiştir. Elde edilen sonuçlar literatürdeki diğer modellerle karşılaştırmalı olarak sunulmuştur [35].

Wang ve ark. çalışmalarında ESA ağ yapısında ve işlemlerinde farklılığa giderek yeni bir kestirim modeli önermişlerdir. Yapılarında ayrılabilir evrişim katmanı kullanmışlar ve önermiş oldukları Derin Ayrılabilir Evrişim Ağındaki (DAEA) evrişim bloğunda atlama bağlantısı ile derin sinir ağının öğrenmesini kolaylaştırmaya çalışmışlardır. Verilerde 14 adet sensörü seçmişler, 0 ile 1 arasına normalize etmişlerdir. Kayan zaman penceresini kullanarak verileri önerdikleri model ile eğitmişlerdir. Elde ettikleri sonuçlar KOKH değeri üzerinden FD001 ve FD003 için alt veri kümesinde literatüre göre en iyi sonuçları sunduklarını raporlamışlardır [36].

Literatürde temelinde ESA yapısının bulunduğu ve C-MAPSS veri kümesinde KFÖ kestirimi yapan çalışmalar Çizelge 3.6'da gösterilmiştir. Çalışmalarda önerilen modele uygun olması için farklı normalizasyon işlemleri ve zaman pencere boyutları kullanılabilir. Son beş yılda yapılan çalışmalarda ESA ağ yapısı C-MAPSS veri kümesinde KFÖ kestirimi için tek başına yeterli gelmediği görülerek hibrit yapılar içerisinde kullanıldığı belirlenmiştir.

Çizelge 1.2 : C-MAPSS veri kümesi üzerinde ESA temelli yapılar ile yapılan çalışmalar.

Kullanılan Yöntemler	KZP (çevrim)	Normalizasyon	Referans
ESA	15	z-skor	[28]
DESA + Seyreltme	30	[-1,1]	[21]
ZEBA	-	z-skor	[34]
AESA	30	[-1,1]	[35]
DAEA	30	[0,1]	[36]

Heimes C-MAPSS veri kümesinin hazırlandığı veri yarışmasında dinamik ağları ilk kez kullanmıştır. Çalışmasında Tekrarlayan Sinir Ağı (TSA) yapısını kullanarak KFÖ kestiriminde yarışmaya katılan diğer algoritmalara göre daha iyi sonuçlar elde etmiştir. Ancak TSA yapısı gereği uzun süreli zamansal verilerdeki başarımları düşmekte ve kaybolan/patlayan gradiyent problemi oluşmaktadır [37].

Zheng ve ark. çalışmalarında UKHA tabanlı bir KFÖ kestirim modeli sunmuşlardır. Zaman serisi olan sensör verilerindeki gizli örüntüleri UKHA katmanı ile yakalamayı ve bozulma modelini kestirmeyi hedeflemişlerdir. Verileri z-skor normalizasyon yöntemi ile önışleme tabi tutmuşlardır. Modellerinde iki katman UKHA, iki katmanda ÇKSA kullanmışlar ve bu katmanlardaki hücre sayılarını değiştirerek başarımlarını karşılaştırmalı veriler ile raporlamışlardır [38].

Wang ve ark. C-MAPSS veri kümesinde KFÖ kestirimde ÇY-UKHA temelli sinir ağı önermişlerdir. Önerdikleri modelde sırasıyla 64 ve 32 hücreden oluşan iki katman ÇY-UKHA, iki katman TBK ve son katman olarak da regresyon katmanı bulunmaktadır [39]. Veri kümesindeki sensörlerden 14 adetini seçmişler ve 0 ile 1 arasına normalize ederek model eğitimi için hazırlamışlardır. Bu model ile zamanda hem ileri yönlü hem de geri yönlü örüntüleri yakalamayı hedeflemişlerdir.

Hsu ve ark. KFÖ kestirimi için UKHA temelli bir sinir ağı önermişlerdir [40]. Önerdikleri model ile zaman serisindeki uzun zamanlı değişkenlerin ve örüntülerin yakalanması hedeflenmiştir. Ayrıca önerilen modelin klasik makine öğrenimi ve ilk ESA modeli ile karşılaştırmalı olarak başarımları gösterilmiştir.

Huang ve ark. ÇY-UKHA temelli KFÖ kestirim modeli sunmuştur. Önerdikleri modelde iki farklı giriş mevcuttur. Bir girişten z-skor normalizasyon ile normalize edilmiş sensör verileri alınıp bir ÇY-UKHA katmanına giriş yapmakta ve çıkışı ile diğer girişten gelen çevresel sensör verileri birleştirilip sonraki ÇY-UKHA katmanına aktarılmaktadır. Ardından iki TBK ve regresyon katmanı ile kestirimler

gerçekleştirilmektedir. Bu çalışma kapsamında FD002 ve FD004 veri kümesi üzerinde çalışılmış ve çevresel etkileri de KFÖ kestirimine etkisini incelemişlerdir [41].

Yu ve ark. ÇY-UKHA temelli öznitelik çıkarımı yapan bir model önermişlerdir. Önerdikleri modelin temelinde Otokodlayıcı yapısı bulunmaktadır ve kodlayıcı ile kod çözücü yapıları ÇY-UKHA temellidir. Yaptıkları çalışmada iki aşamalı bir KFÖ kestirimi mevcuttur. Yapıda kodlayıcı çıkışında elde edilen değerler ile Sİ kütüphanesi oluşturulup elde edilen bu verilerden doğrusal regresyon ile KFÖ kestirimi yapılmıştır [42].

Miao ve ark. yaptıkları çalışmada UKHA temelli bir model ile C-MAPSS veri kümesi üzerinde çalışmışlardır. Çalışmada önerilen model ile KFÖ kestirimi ve sınıflandırmayı aynı anda yapmaya çalışmışlardır. Model girişinde uygulanan veriler belirtmiş oldukları önişleme tabii tutulmuş ve iki katman UKHA ardından da TBK kullanılarak çıkış alınmıştır. Ağ yapısının iki farklı çıkışı vardır ve ilk çıkış ile motorun hangi durumda olduğunu gösteren bir sınıflandırma, ikinci çıkış ile de KFÖ kestirimi yapılmaktadır. Elde edilen sonuçlar KOKH ile karşılaştırmalı olarak sunulmuştur [43].

Zhang ve ark. çalışmalarında UKHA temelli bir model önermişlerdir. Önerdikleri modelde paralel iki UKHA yapısı mevcuttur. Bu paralele yollarda iki katman UKHA ve seyreltme katmanı bulunmaktadır. Çıkışları birleştirilerek çıkış katmanı elde edilmiş ve KFÖ kestirimi yapılmıştır. Literatürdeki diğer çalışmalardan farklı olarak bozulma modelinde doğrusal bozulma modeli kullanarak eğitim ve kestirimi gerçekleştirmişlerdir. Önerdikleri modelin sonuçlarını karşılaştırmalı olarak sunmuşlar ve FD001 ile FD003 için KOKH için literatüre göre iyi sonuçlar elde etmişlerdir [44].

Literatürde TSA temel alan ve onun üzerine inşa edilen derin sinir ağları modellerinin karşılaştırması Çizelge 3.7'de yapılmıştır. İncelenen yapılara göre normalizasyon işlemleri benzer yapıya sahip olsalar da modeller farklılaştıkça sonuçlara olan katkı değişmektedir.

Çizelge 1.3 : C-MAPSS veri kümesi üzerinde TSA temelli yapılar ile yapılan çalışmalar.

Kullanılan Yöntemler	KZP (çevrim)	Normalizasyon	Referans
TSA	-	-	[37]
UKHA + Seyreltme	10	z-skör	[38]
ÇY-UKHA	-	[0-1]	[39]
UKHA	-	z-skör	[40]
ÇY-UKHA	15	z-skör	[41]
ÇY-UKHA	10	z-skör	[42]
UKHA	-	z-skör	[43]
UKHA + Seyreltme	-	z-skör	[44]

Literatürde ESA temelli modellerde lokal özniteliklere odaklanarak kestirimler yapılmıştır. Dinamik ağlarda TSA, UKHA ve GYB yapılarını kullanarak zaman serisindeki geçmişe dayalı öznitelikleri bularak regresyon probleminde kullanılmıştır. Ancak her bir yapının kendine özgü kısıtlamaları olmuş ve hibrit modeller ile geliştirilmeye çalışılmıştır. Bu alanda Al-Dulaimi ve ark. literatüre paralel kollara sahip hibrit bir model sunmuşlar ve elde ettikleri sonuçlarda literatürdeki diğer sonuçlara göre ilerleme kaydetmişlerdir. Önerdikleri modelde UKHA ve ESA yapıları paralel olarak kullanmışlardır. Paralel kollardan mekansal ve zamansal öznitelikler elde edilmek istenmiştir. Bu öznitelikler TBK ile birleştirilip son katmanı ile de kestirim yapılmıştır. Bu çalışmada kayan zaman penceresi kullanılmış ve 21 adet sensörden 14'ü seçilerek giriş verisi tekrardan düzenlenmiştir. Önerilen model ile hibrit yapıların KFÖ kestirimlerindeki başarımları gözlenmiştir [45].

Liu ve ark. yapmış oldukları çalışmada C-MAPSS veri kümesinde farklı derin öğrenme tekniklerini birleştirerek hibrit bir model sunmuşlardır. Çalışmada veri kümesinin tüm alt veri kümelerinde çalışmışlar ve kayan zaman pencere tekniği ile verileri işlemişlerdir. Verilerini -1 ile 1 arasına normalize etmişlerdir. Önerdikleri modelin girişinde özniteliklere odaklanan Dikkat Katmanı kullanmışlardır. Ardında Çift Yönlü Geçitli Tekrarlayan Birim (ÇYGTB) katmanı ile ESA yapısı kullanmışlardır. Regresyon yapısı için ÇKSA kullanarak kestirim gerçekleştirmişlerdir. Aldıkları sonuçları literatür ile karşılaştırmalı olarak sunmuşlardır [46].

Zhang ve ark. çalışmalarında hem derin sinir ağı yapılarını hem de toplu öğrenme algoritmasını kullanmıştır. Uçak motoru veri kümesinde Derin İnanç Ağları (DİA) ile denetimsiz öznitelik çıkarımı yapmış ve farklı ağ yapılarının çıktılarını toplu öğrenme

algoritması ile birlikte kullanmıştır. Bu çalışmanın toplu öğrenme yapısında hem KFÖ kestirim hassasiyeti arttırılmak istenmiş hem de çeşitlilik sağlanarak daha gürbüz bir yapı sunulmaya çalışılmıştır. Elde edilen sonuçlar diğer makine öğrenimi algoritmaları karşılaştırılmıştır [29].

Chen ve ark. çalışmalarında veri kümesini normalize edip kayan pencere metodunu kullanmışlardır. Elde edilen bu ham veriden ortalama ve eğilim öznitelikleri çıkarmışlar ve önerdikleri modele iki farklı giriş olarak vermişlerdir. Ham veriler UKHA ve ardından gelen Dikkat katman ve iki TBK ile işlenmiştir. Elle çıkarılan öznitelikler ise diğer koldan tek TBK ile işlenmiş ve tüm işlenen değerler birbirine eklenmiştir. Son katmanda ise regresyon yapılmış ve elde edilen sonuçlar karşılaştırmalı olarak sunulmuştur [47].

Palazuelos ve ark. C-MAPSS veri kümesi üzerinde KFÖ kestirim modeli üzerinde çalışmalar yapmışlardır. Hinton ve ark. önermiş oldukları Kapsül Ağları yapısını uçak motoru veri kümesi için uyarlamışlardır. Karmaşık koşullara sahip FD002 ve FD004 veri kümelerinde literatürdeki diğer çalışmalara göre umut verici sonuçlar elde etmişlerdir [48].

Li ve ark. çalışmalarında ESA ve UKHA katmanlarını birlikte kullanmışlardır. Bu iki katmanı Yönlendirilmiş Döngüsüz Grafiği (YDG) ile bir araya getirmişlerdir. Öznitelik çıkarımı aşamasında ESA ağları kullanılmış ve zaman uzayındaki öznitelikler içinde UKHA katmanı kullanılmıştır. Paralel gelen bu kollar UKHA katmanı ile birleştirilmiş ve regresyon katmanı ile de kestirimler yapılmıştır. C-MAPSS veri kümesi üzerinde literatüre yeni bir yaklaşım kazandırılmış ve umut verici sonuçlar elde edilmiştir [49].

Kong ve ark. çalışmalarında ESA ve UKHA yapılarını birbirine kaskat bağlayarak bir derin öğrenme modeli sunmuşlardır. Ayrıca çalışmalarında 21 sensörden bir bölümünü seçmişler ve normalize ettikten sonra kullanmışlardır. UKHA yapısından sonra TBK yapısını kullanarak kestirim yapmışlar ve elde ettikleri sonuçları sunmuşlardır. [50].

Costa ve ark. çalışmalarında C-MAPSS veri kümesin üzerinde UKHA ve Dikkat katmanının olduğu bir kestirim modeli önermişlerdir. Çalışmalarında kayan zaman penceresi kullanmışlar ve verileri 0 ile 1 arasına normalize ederek model eğitimi için hazır hale getirmişlerdir. Önerdikleri modelde UKHA yapısına veriler giriş olarak alınmakta ve çıkışında da Dikkat katmanı ile gerekli olan özniteliklere odaklanması

sağlanmaktadır. Ardından TBK ile KFÖ kestirimi yapılmaktadır. Ayrıca çalışmada dikkat katmanı önerilen modelden çıkarılarak sonuçlara olan etkisi de incelenmiştir. Elde edilen sonuçlar karşılaştırmalı olarak hem KOKH hem de skor fonksiyonu için sunulmuştur. FD003 için literatüre göre skor fonksiyonu üzerinden iyi sonuçlar aldığı bildirilmiştir [51].

Ragab ve ark. dikkat yapısını temel alan diziden diziye bir yapı öne sürmüşlerdir. Yaptıkları çalışmada çok amaçlı optimizasyon ile iki kayıp fonksiyonunu birleştirmişlerdir. UKHA ve Dikkat katmanlarından oluşan kodlayıcı yapısı ve UKHA ile TBK'dan oluşan kod çözücü yapısı kurulmuş ve bu Otokodlayıcı ile sonraki sensör değerleri elde edilmeye çalışılmıştır. Buradan elde edilen kayıp fonksiyonu ile kodlayıcı ve kod çözücü katmanlarından gelen öznitelikler TBK ile KFÖ kestiriminde kullanılmış ve buradaki kayıp fonksiyonu birleştirilmiştir. Bu çalışma kapsamında 14 tane literatür çalışması ile karşılaştırılmış ve başarılı sonuçlar elde edilmiştir [52].

Al-Dulaimi ve ark. daha önce yapmış oldukları hibrit ve paralel modellerini geliştirerek KFÖ kestirimi için yeni bir model sunmuşlardır. Önerdikleri modelde paralel kolların birinde mekansal öznitelikler için ESA, zamansal öznitelikler için ÇYGTB yapısını kullanmışlardır. Diğer modelden farklı olarak paralel kollarda ve özniteliklerin birleştiği ağ yapısının ilk katmanında Gaussian gürültü katmanı kullanmasıdır. Böylelikle her katmanda gürültü ekleyerek modeli daha gürbüz hale getirmeyi hedeflemişlerdir. Elde ettikleri sonuçlara göre literatürde tüm veri kümeleri için ilerleme kaydetmişlerdir [53].

Al-Dulaimi ve ark. başka bir çalışmasında ise hibrit ve paralel yaklaşımın olumlu etkisi ile daha karmaşık yapıya sahip FD002 ve FD004 alt veri kümelerinde yeni bir model sunmuşlardır. Bu modellerinde ise paralel kollarda ESA, ÇKSA ve ÇYGTB yapıları bulunmaktadır. Ayrıca bu paralel kollarda Gaussian gürültü de ekleyerek farklı çalışma modlarındaki motorlar için daha gürbüz bir kestirim modeli sunmak istemişlerdir. Ayrıca paralel kollar bileştikten sonra TBK ile regresyon katmanına bağlamışlardır. Elde ettikleri sonuçları literatürdeki diğer başarılı sonuçlarla karşılaştırmış ve üstünlüklerini belirtmişlerdir [54].

Dikkat mekanizmasının Doğal Dil İşleme (DDİ) alanında yapmış olduğu başarımla ile başka alanlarda kullanımı da hızla artmıştır. Xia ve ark. C-MAPSS veri kümesi üzerinde UKHA temelli Çok katmanlı Öz-Dikkat modelini KFÖ kestiriminde

kullanmışlardır. Öz-Dikkat katmanları ile zaman ekseninde önemli noktalara odaklanılmış ardından UKHA katmanları ile öznitelikler çıkarılmıştır. Bağlı katmanlar ve regresyon çıkış katmanları ile kestirimleri gerçekleştirmiştir [55].

Tan ve ark. yaptıkları çalışmada ESA ve Dikkat yapılarını birlikte kullanmışlardır. ESA ile farklı boyutlardaki zaman serilerinde öznitelik çıkarımı yapmış ve Dikkat katmanı ile ilgili özniteliklere odaklanılmıştır. Elde edilen sonuçlar geliştirilmesi gereken bir ağ yapısı olduğunu göstermektedir [56].

Park ve ark. C-MAPSS veri kümesi üzerinde paralel kollara sahip bir sinir ağı önermişlerdir. Önerdikleri modelin bir kolunda ÇY-UKHA yapısı mevcutken diğer kolda ise Dikkat yapısına sahip bir ağ vardır. Bu iki kolun çıkışı içerisinde Artık Bloklar barındıran birleştirilmiş ağ ile çıkışa bağlanmaktadır. Yapılan KFÖ kestirimi çalışmasında literatüre göre umut verici sonuçlar elde edilmiştir [57].

Remadna ve ark. KFÖ kestirimi probleminde hibrit bir yaklaşım sergileyerek Evrimsel Otokodlayıcı (EO) tabanlı paralel ÇYGTB ve ÇY-UKHA modeli önermişlerdir. Önerdikleri modelde EO ile denetimsiz bir şekilde öznitelik çıkarımı yapmışlardır. Elde ettikleri öznitelikleri paralel yapıya sahip ve bir kolunda ÇYGTB diğer kolunda ÇY-UKHA bulunan modele giriş olarak vermişlerdir. Böylelikle öznitelikler arasında zaman boyutunda ilgili olanlara yakalamayı çalışmışlar ve elde ettikleri sonuçlara bakıldığında özellikle FD001 için KOKH değeri literatüre göre en iyi sonuçları vermiştir [58].

Literatürde hibrit yapıya sahip derin sinir ağları modellerinin karşılaştırması Çizelge 3.8'de yapılmıştır. İncelenen yapılara göre normalizasyon işlemleri benzer yapıya sahip olsalar da modeller farklılaştıkça sonuçlara olan katkı değişmektedir. Ayrıca literatürde yapılan çalışmalar hibrit yapılarda daha başarılı olarak raporlandığı için son yıllarda önerilen modeller birçok farklı ağ yapısının bir araya gelerek oluşturulan modellerden meydana gelmektedir.

Çizelge 1.4 : C-MAPSS veri kümesi üzerinde hibrit yapılar ile yapılan çalışmalar.

Kullanılan Yöntemler	KZP (çevrim)	Normalizasyon	Referans
HDSA	-	-	[45]
ÖGESA	30	[-1,1]	[46]
(MODBNE)ÇGDİA	30	[-1,1]	[29]
DK temelli- UKHA	30	-	[47]
Kapsül Ağları	30	[0,1]	[48]
(DAG)(YDG)	30	z-skor	[49]
(CNN-LSTM-NN)ESA-UKHA-SA	-	z-skor	[50]
(LSTM-A) UKHA-DK	30	[0-1]	[51]
(ATS2S) DKDD	30	[0-1]	[52]
(NPBGRU)GPÇY-GYB	30	[-1,1]	[53]
(NMPM)GÇYPM	30	[-1,1]	[54]
(LSTM-MLSA) UKHA-ÇKÖD	-	[0,1]	[55]
(CNN-ATT) ESA-DK	-	[0,1]	[56]
(PAN) PDA	30	[0,1]	[57]
(CAE-BDGRU-BDLSTM) EO- ÇYGYB-ÇYUKHA	-	[0,1]	[58]

Literatürde rulmanlar üzerinde yapılan KFÖ kestirim çalışmaları farklı yaklaşımlar ile incelenmiştir. Bu çalışma kapsamında FEMTO-ST veri kümesi üzerindeki çalışmalar incelenmiş ve literatürdeki farklı yaklaşımlar incelenerek raporlanmıştır. Chen ve ark. yapmış oldukları çalışmada FEMTO-ST veri kümesi üzerinde KFÖ analizi ve Sİ tahmini yapmışlardır. Çalışmalarında öncelikle Sİ hesaplaması yapılmış ardından bu değerlerden doğrusal regresyon ile KFÖ kestirimi yapmışlardır. Veri kümesinin yüksek örnekleme frekansına sahip olması ile frekans bandını beşe bölerek 10 farklı öznitelik çıkarmışlar ve bu öznitelikleri 0 ile 1 arasına normalize ederek önermiş oldukları modelde kullanmışlardır. Bu modeli ESA yapısı ile başlatmışlar ve ardından ÇYGTB kullanmışlardır. ÇYGTB yapısını da Otokodlayıcı içerisnde kullanmışlar ve ardından GTB ile Dikkat mekanizmasını birleştirip çıkış katmanına bağlamışlardır. Elde ettikleri sonuçları her bir test rulmanı için karşılaştırmalı olarak sunmuşlardır [59].

Ren ve ark. KFÖ kestirimini rulman veri kümesi üzerinde yapmışlardır. Veri kümesinden zaman uzayında Karekök Ortalama Kare (KOK), basıklık ve tepe faktörü olmak üzere üç adet öznitelik ve frekans uzayında Frekans Spektrumu Bölümleme Toplamından (FSBT) 5 adet öznitelik çıkarılarak model eğitiminde kullanmışlardır. Çalışmalarında veri kümesinin birinci çalışma koşullarındaki rulmanları test ederek raporlamışlardır. Bu çalışmada DVM, YSA, DSA, Gradyan Artırma Karar Ağacı

(GAKA), Bayes Sırtı ve Gauss regresyon yöntemleri ile kestirimler yapmışlar ve karşılaştırmalı olarak KOKH üzerinden sunmuşlardır [60].

Loutas ve ark. çalışmalarında veri temelli bir yaklaşım ile KFÖ kestirimi modeli sunmuşlardır. Çalışmalarında zaman uzayından, frekans uzayından ve zaman-frekans uzayından elde etmiş oldukları öznelikleri kullanarak DVR algoritması ile kestirim gerçekleştirmişlerdir. Bu çalışma kapsamında veri kümesindeki tüm rulmanlar kullanılmamış, farklı bir senaryoda eğitim ve test gerçekleştirilmiştir. Elde edilen sonuçları karşılaştırmalı olarak rapor etmişlerdir [61].

Cheng ve ark. yapmış oldukları çalışmalarında rulmanlar üzerindeki KFÖ kestiriminde derin öğrenme teknikleri kullanmışlardır. Çalışmalarında titreşim verilerine öncelikle Hilbert Dönüşümü ardından Marjinal Hilbert Spektrumu tekniği uygulayarak öznelik çıkarımı yapmışlardır. Elde ettikleri bu öznelikler ile iki evrişim katmanlı ESA yapısı kullanmışlar ve KFÖ kestirimi gerçekleştirmişlerdir. Önerilen model veri yarışmasındaki eğitim ve test senaryosu yerine farklı bir senaryoda test edilmiştir. Literatürdeki çalışmalar ile karşılaştırması yapılmıştır [62].

Sutrisno ve ark. çalışmalarını rulman titreşim verilerinden öznelik çıkarımı yaparak KFÖ tespiti ve anomali tespiti üzerinde yapmışlardır. Çalışmalarında 34 farklı öznelik kullanmışlar ve bu öznelikleri zaman ve frekans uzayında sinyal işleme yoluyla elde etmişlerdir. Ardından özneliklerin gürültüsünü azaltmak için yumuşatma işlemi ve normalizasyon işlemine tabi tutmuşlardır. KFÖ kestirimi içinde DVR algoritmasını kullanmışlardır [63].

Hinchi ve ark. rulman döner makine elemanlarında KFÖ kestirimi için hibrit bir derin öğrenme yöntemi sunmuşlardır. Çalışmalarında ham veriden öznelik çıkarımı yapmışlar ardından önermiş oldukları modelde eğitmişlerdir. Bu model yapısında sırasıyla ESA ve UKHA yapılarını kullanmışlar ve çıkışında regresyon yapmışlardır. Eğitim sırasında modelin verilerde ezberleme yapmaması için seyreltme işlemi uygulamışlar ve elde ettikleri sonuçları karşılaştırmalı olarak sunmuşlardır [64].

Lei ve ark. çalışmalarında FEMTO-ST veri kümesi için indikatör üretimi ve KFÖ kestirimi üzerine çalışmışlardır. Rulmanlara ait titreşim verilerinden zaman, frekans-zaman ve trigonometrik öznelikler çıkarmış ve bunları korelasyon ile test etmişlerdir. Ardından model için gerekli öznelikler seçerek indikatör üretiminde kullanmışlardır. KFÖ kestirimini Parçacık Süzgeci uygulamasını kullanarak gerçekleştirmişlerdir. Elde

ettikleri sonuçları veri yarışmasındaki test rulmanlar üzerinde yapmışlar ve karşılaştırmalı olarak sunmuşlardır [24].

Hong ve ark. çalışmalarında rulman veri kümesinde KFÖ tahmini için sinyal işleme yöntemlerini kullanmışlardır. Titreşim verilerinden zaman uzayından öznitelikler çıkarılmıştır. Ayrıca Dalgacık Dönüşümü kullanılarak öznitelikler çıkarılarak diğer özniteliklere eklenmiştir. Denetimsiz öğrenme sinir ağı ile sağlık indikatörü oluşturmuşlar ve KFÖ kestirimi yapmışlardır [65].

Chen ve ark. çalışmalarında önermiş oldukları derin öğrenme modeli ile iki farklı hedefi gerçeklemeye çalışmışlardır. FEMTO-ST veri kümesinde üç farklı rulman çalışma koşulunun mevcut olması sebebiyle bunların arasında domain adaptasyonu hedefi ile titreşim verilerinden KFÖ kestirimi üzerinde çalışmışlardır. Bu çalışma kapsamında bir boyutlu ESA yapısını temel alan bir model önermişlerdir. Çıkışa yakın TBK ikiye ayrılarak iki farklı çıkış için tasarlanmış ve eğitilmiştir. Yapılan çalışma veri yarışmasının senaryosunun dışında bir senaryo ile yapılmış ve elde edilen sonuçlar da skor değerlendirme fonksiyonu dışındaki metrikler ile de sunulmuştur [66].

Ren ve ark. çalışmalarında KFÖ kestirimi için veri temelli bir yaklaşım sunmuşlardır. Titreşim verilerinde monotonluk ve süreklilik incelemesi yapmışlar ve öznitelik çıkarımında bulunmuşlardır. Sözlük öğrenme tekniği ile parametre kestirimi yapılmış ve KFÖ tahmini yapılmıştır. Elde edilen sonuçlar test veri kümesindeki her bir rulman için Çizelge halinde sunulmuş ve raporlanmıştır [67].

Zhang ve ark. yaptıkları çalışmalarda rulmanlar üzerinde KFÖ dışında rulmanlara ait arızanın kaynağının tespiti üzerine de çalışmışlardır. Çalışmalarında yeni derin bir ESA modeli önermişlerdir. Model yapısını da ham veriler üzerinde kullanmışlardır [68,69].

Bu tez kapsamında KFÖ kestiriminde C-MAPSS uçak motoru verileri ile FEMTO-ST rulman verileri kullanılmıştır. Her iki veri kümesi için literatürde farklı çalışmalar yapılmış ve başarımlar sergilenmiştir. Son yıllarda derin öğrenme alanındaki gelişmelerle KFÖ kestiriminde derin öğrenme yöntemleri kullanılmıştır. Özellikle Öz-Dikkat katmanı yapısının doğal dil işleme ve sonrasında da diğer alanlardaki başarımları ile bu çalışmaya dahil edilmiştir. Uçak motoru veri kümesinde Öz-Dikkat katmanının yanında ResNet katmanı ve modelin ezberlemesinin önüne geçmesi için Gauss Gürültü Katmanı kullanılmıştır. Ayrıca bu probleme özgü olarak model

eđitiminde kullanılmak üzere deęerlendirme metrięinin yapısına benzer asimetric bir kayıp fonksiyonu önerilmiř ve model bununla eđitilmiřtir. Önerilen derin öęrenme yapısıyla Karekök Ortalama Karesel Hata (KOKH) deęerlendirme metrięinde ve bu problem için önerilen skor fonksiyonunda başarılı sonuçlar elde edilmiřtir. Veri kümesine ait FD001, FD002, FD003 ve FD004 alt veri kümelerinde KOKH deęerinde sırasıyla 11.017, 23.14, 12.62, 26.39 deęerleri elde edilmiřtir. Skor deęerinde ise sırasıyla 157.19, 2490.09, 218.6, 3800.15 sonuçları bulunmuřtur. Elde edilen bu sonuçlar literatürdeki dięer çalıřmalarla karřılařtırılmalı olarak sunulmuř ve özellikle FD001 alt veri kümesindeki üstün başarıyı belirtilmiřtir.

Bu çalıřma kapsamında rulman titreřim verilerinde önerilen derin öęrenme modeli ise son yıllarda sıklıkla kullanılan Dönüřtürücü yapısını temel almaktadır. Öz-Dikkat katmanına da içeren Dönüřtürücü yapısı önerilen model içerisinde titreřim verilerinden öznitelik çıkarımı ve KFÖ kestirimi yapısında kullanılmıř ve başarılı sonuçlar elde edilmiřtir. Rulmanlar üzerinde yapılan kestirimlerin karřılařtırmasında veri yarışmasında önerilen skor fonksiyonu kullanılmıřtır. Bu deęerlendirme metrięine göre 0.433 deęeri elde edilmiř ve literatürdeki çalıřmalara göre başarıyı üstünlüęü karřılařtırılmalı tablolar ile verilmiřtir.

Bu tez çalıřması ile literatüre KFÖ kestirimi için yeni modeller sunulmuřtur. Bununla birlikte yeni bir kayıp fonksiyonu önerilmiř ve başarıları karřılařtırılmıřtır. Her iki veri kümesindeki üstün başarıları belirtilmiřtir.

Tez çalıřmasının ikinci bölümünde her iki veri kümesinde kullanılmıř olan yöntemler detaylıca anlatılmıřtır. Çalıřmanın üçüncü bölümünde C-MAPSS uçak motoru veri kümesinin detaylarına girilmiřtir. Ayrıca bu veri kümesi için önerilen model detaylıca sunulmuřtur. Öniřleme adımıyla yapılanlar anlatılmıř ve elde edilen sonuçlar bildirilmiřtir. Son kısmında ise önerilen modelin belirli katmanlarının sonuca olan etkisi incelenmiřtir. Dördüncü bölümde FEMTO-ST rulman veri kümesi tanıtılmıř ve üzerinde yapılan öniřleme adımları belirtilmiřtir. Bu çalıřma için önerilen model detaylıca anlatılmıřtır. Son kısmında ise elde edilen sonuçlar sunulmuř ve literatür ile olan karřılařtırılması yapılmıřtır. Tezin son bölümünde ise gelecek çalıřmalardan ve bu çalıřma kapsamındaki tartıřmalardan bahsedilmiřtir.

2. METOT

2.1 Yapay Sinir Ağları

Yapay Sinir Ağları (YSA) insan beyin faaliyetlerinden esinlenerek oluşturulan ve doğrusal olmayan mekanizmaya sahip bir yapıdır. Bu yapı içerisinde beyindeki nöronları ve birbirilerine olan bağlantılarını taklit eden birimler bulunmaktadır. Bu nöron yapıları ağırlık katsayıları ile tek yönlü olarak birbirine bağlanarak katmanlar oluşturmaktadır [70]. YSA yapıları Makine Öğrenimi (MÖ) algoritmaları arasında tanımlanmaktadır. Gelişen yöntemler, artan veri miktarı ve işlem gücü ile birlikte YSA yapıları karmaşık problemlerin üzerinden diğer MÖ algoritmalarına göre daha başarılı olarak sonuçlar vermektedir. Sinir ağı yapıları uygun mimari ve ağırlık katsayılarına göre doğrusal olmayan örüntülere sahip problemlerde ve süreklilik arz eden durumlarda matematiksel olarak üstesinden gelebilmektedir [71]. Yapay sinir ağları diğer MÖ algoritmalarına göre yüksek hesaplama gücü sayesinde büyük veriler ile daha iyi başa çıkabilmektedir. Ayrıca gürültüyü filtreleme, ağ yapısına göre ilişkili verileri analiz edebilme ve veriden istenilen modeli yüksek doğrulukla hesaplayabilme yeteneğine sahiptir. Bu üstünlükleri sebebiyle özellikle hata teşhisi, hata kestirimi ve bakım kestirimi çalışmaları olmak üzere, uzay ve havacılık, üretim, mühendislik, savunma, finans, güvenlik ve haberleşme gibi alanlarda sıkça kullanılmaktadır [72-74].

Yapay sinir ağlarının başarılı yapısı ve artan işlem gücü ile birlikte son 15-20 yıla damga vuran Derin Öğrenme (DÖ) algoritmalarına evrilmiş ve hızla gelişmeye, büyümeye ve farklı uygulanma alanlarında kullanılmaya başlanmıştır. Derin öğrenme algoritmalarının YSA yapısından farkı gizli katmanlarının iki veya daha fazla olmasıdır. Ayrıca resim, ses veya sensör verileri ile metin verilerini başarılı bir şekilde analiz etmesi, özetleyip istenilen şekilde sunabilmesidir. Derin öğrenme yapısında katman sayısının artması yani derinlik kavramının artması kullanılan verilerde daha iyi öğrenmeye izin vermekte ve başarılı sonuçların alındığı gözlenmektedir. Makine öğrenimi algoritmaları kullanılırken probleme özgü uzman bilgisi ile beraber verilerden uygun özniteliklerin el yordamıyla çıkarılması ve algoritmaya uygulanması gerekmektedir. Ancak derin öğrenme çok katmanlı ve doğrusal olmayan yapısı sayesinde verilerden probleme uygun özniteliklerin otomatik çıkarılmasını ve istenilen çıktılar elde edilmesini sağlamaktadır [71].


Derin öğrenme de dahil olmak üzere makine öğrenimi algoritmaları amaçlarına bağlı olarak 3 farklı grupta incelenebilmektedir. Bu öğrenme grupları denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak isimlendirilmektedir. Denetimli öğrenme problemlerinde öğrenme algoritmasına giriş verisi ile birlikte istenilen çıkış verisi de verilmektedir. Algoritma yapısı gereği gerçek çıktı verisi ile kestirilen çıktı verisini karşılaştırıp hatayı hesaplayarak gerekli güncellemeleri yapmaktadır. Burada kullanılan çıkış verileri ayrık yapıya sahip olabileceği gibi süreklilik arz eden gerçek değerler de olabilmektedir. Ayrıca bu yöntem ile sınıflandırma veya regresyon problemleri çözülmektedir [75]. Denetimsiz öğrenme algoritmaları problemlerde herhangi etiketli bir verinin olmadığı veri kümelerinde çalışılmaktadır. Bu yapılar uzman bilgisi gerektirmeden verideki yararlı bilgileri ortaya çıkarmak ve analiz etmek için kullanılmaktadır. Denetimsiz öğrenme yapıları kümeleme işlemlerinde kullanılmaktadır. Veri kümesinde gizledikleri örüntülere göre kümeleme işlemi yapan ve analizini gerçekleyen yapılardır [76]. Ayrıca yüksek boyutlu verilerde herhangi bir etiket gerektirmeden ve gerekli bilgiyi kaybetmeden boyutunun azaltılmasında da kullanılmaktadır [77]. Pekiştirmeli öğrenme yapısı ajan veya öğrenen, ajanın eylemleri ve çevre olmak üzere üç temel bileşenden oluşmaktadır. Bu öğrenme yapısında belirli zaman aralıklarında ajan çevre ile etkileşime girerek istenilen eylemleri yerine getirmesi beklenmektedir. Ajan çevre ile etkileşime girdiğinde istenilen hedefe göre ödül ve ceza sistemi devreye girerek geri besleme yapmaktadır. Böylelikle algoritma iyi bir eylem politikası izleyerek elde ettiği ödülü maksimize etmeye çalışmaktadır [78]. Bu öğrenme yapısı oyun, navigasyon, otonom sürüş ve robotik alanında sıklıkla kullanılmaktadır. Bu tez çalışmasında kullanılan tüm algoritmaları denetimli öğrenme başlığı altında geliştirilmiş ve uygulanmıştır.

Kullanılan verinin yapısına, öğrenme sürecine veya problemin kendine has özgünlüğüne göre farklı yapılara sahip YSA oluşturulmuştur. Oluşturulan bu YSA yöntemleri kullanılan alana göre genel itibari ile derin öğrenme başlığı altında anılmaktadır. Bu teknikler çok katmanlı sinir ağları, evrimsel sinir ağları ve türevleri, tekrarlayan sinir ağları ve türevleri, öz-dikkat ve türevleri ile dönüştürücü yapılarından oluşmaktadır. Bu tez kapsamında kullanılan diğer yöntemler bölümün geri kalan kısmında detaylıca açıklanmıştır.

2.2 Çok Katmanlı Sinir Ağı

Çok Katmanlı Sinir Ağı (ÇKSA), YSA temelini oluşturduğu için sinir ağı modellerinin ya tamamında ya da katmanlarının bir bölümünde kullanılmaktadır. Yapı olarak diğer sinir ağı tekniklerinin genellikle sonlarında olmak ile birlikte bir kısmını meydana getirmektedir. ÇKSA ileri beslemeli bir yapıya sahiptir ve kendisini besleyen nöron katmanlarına göre aktive olmaktadır. Ayrıca ÇKSA yapıları ileri beslemeli genel bir yapıya sahip olmalarından dolayı türetilen modellerde İleri Beslemeli Sinir Ağı (İBSA) olarak da anılmaktadır. Yapı olarak girdi katmanı, gizli katmanlar ve çıkış katmanı olmak üzere üç temel bileşeni bulunmaktadır. Her katmanda bulunan nöronlar kendisine gelen bağlantılarda bir ağırlık katsayısı barındırmakta ve gelen sonuca göre bir çıkış üretmektedir.

Şekil 2.1’de ÇKSA yapısı görülmektedir. Bu yapı birer adet giriş katmanı, gizli katman ve çıkış katmanında oluşmaktadır. Bu yapıda gizli katman sayısının ikiden fazla olacak şekilde artırılması ile derin sinir ağı (DSA) yapısının oluşturulması sağlanmış olacaktır.



Şekil 2.1 : Çok katmanlı sinir ağının temel yapısı.

Şekilde görülen $i \in \mathfrak{R}^n$ giriş vektörünü ifade etmektedir. Gizli katmanın çıkışı ile çıkış katmanın çıkışını sırasıyla $h \in \mathfrak{R}^k$, $o \in \mathfrak{R}^m$ ile ifade edilmektedir. ÇKSA yapısının giriş verisinden çıkış bilgisinin alınımına kadar yapılan işlemler aşağıda verilmektedir.

$$h = \gamma(W_0 i + b_0) \quad (2.1)$$


$$o = \gamma(W_1 h + b_1) \quad (2.2)$$

Giriş katmanı ile gizli katman arasındaki ağırlıklar ise $W_0 \in \mathfrak{R}^{k \times n}$ ile ifade edilmektedir. Aynı şekilde gizli katman ile çıkış katmanı arasındaki ağırlık katsayıları ise $W_1 \in \mathfrak{R}^{m \times k}$ ile ifade edilmektedir. İki katmanda bulunan yanlılık değerleri b_0, b_1 olarak verilmiştir. Doğrusal olmayan bir sistemi sağlayabilmek için de γ aktivasyon fonksiyonları kullanılmıştır. Kullanılan aktivasyon fonksiyonları giriş verisi ile çıkış verisi arasında doğrusal olmayan bir ilişki kurulmasını sağlar. Böylelikle beyin yapısında bulunan nöronların yapısına daha uygun bir özellik kazandırılmış olur. Gerçek dünyadaki karmaşık problemlerde doğrusal olmayan aktivasyon fonksiyonlarının kullanımı ve derin ağ yapıları ile veriler arasındaki ilinti bulunabilmektedir. Literatürde YSA ve DÖ algoritmalarında sıklıkla kullanılan ve son zamanlarda öne çıkan aktivasyon fonksiyonları ve formülleri Çizelge 2.1’de verilmiştir.

Çizelge 2.1 : Aktivasyon fonksiyonları.

Fonksiyon	Formül	Çıkış Aralığı
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$	(0,1)
Tanh	$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$	[-1,1]
ReLU	$f(x) = \max(0, x)$	[0,∞)
LeakyReLU	$f(x) = \max(\alpha x, x)$	(-∞,∞)
GeLU [79]	$f(x) = 0.5x(1 + \tanh[\sqrt{\frac{2}{\pi}}(x + 0.044715x^3)])$	[-0.17,∞)
Softmax	$f(x) = \frac{e^{x_i}}{\sum_k e^{x_k}}$	[0,1]


Çizelge 2.1’de gösterilen aktivasyon fonksiyonlarının karşılaştırmalı grafikleri Şekil 2.2’de gösterilmiştir.



Şekil 2.2 : Aktivasyon fonksiyonlarının karşılaştırmalı grafiği.

2.3 Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (ESA) Hubel ve Wiesel'in bir kedinin görsel sistemini incelediği ve görme sürecinin nasıl çalıştığını anlamaya çalıştıkları deneysel sürece dayanmaktadır [80]. Bu deney kapsamında görsel bilginin belirli alanları ilgili nöronları uyardığı görülmüştür. Bu çalışmaya dayanarak ESA yapısı ilk olarak LeCun ve ark. tarafından 1989 yılında el yazısı tanıma problemi üzerinde LeNet ismiyle sunulmuştur [81]. Önerilen LeNet-5 mimarisi Şekil 2.3'te gösterilmiştir. Bu ağ yapısında evrişim işlemi, havuzlama ve tam bağlı katmanlar bulunmaktadır.




Şekil 2.3 : LeNet-5 evrişimsel sinir ağı.

Kuruluş amacına binaen ESA bilgisayarlı görme alanında nesne tanıma ve görüntüleri sınıflandırma uygulamalarında temel algoritma olarak kullanılmaya başlanmıştır. ESA yapısının özellikle mekansal özellikleri çıkarmadaki yeteneği sebebiyle güçlü bir öznitelik çıkarıcı olarak görev yapmakta ve farklı araştırma alanlarında kullanılabilir. Zaman geçtikçe kullanılan verilerin miktarı arttıkça ve

hesaplama gücündeki artışla birlikte sinir ağları derin yapılar olarak karşımıza çıkmıştır.

2012 yılında AlexNet yapısı ile ImageNet yarışmasında elde edilen iyi sonuçlar bu ağlara olan ilgiyi arttırmıştır [82]. Bu derin sinir ağı yapısında birçok sinir katmanı ve evrişim katmanı bulunmaktadır. Ayrıca eğitim için kullanılan ağırlık katsayıları miktarı yüksek olması ve bu ağırlık katsayılarının eğitiminin paralel işlem gücü ile yapılarak başarılı sonuçlar elde edilmesi bu çalışmaya odaklanılmasını sağlamıştır. AlexNet sinir ağı yapısı Şekil 2.4'te gösterilmiştir ve bu yapıyla birlikte derin öğrenmeye ve evrişimsel sinir ağlarına olan ilgi artmıştır.




Şekil 2.4 : AlexNet derin evrişimsel sinir ağı.

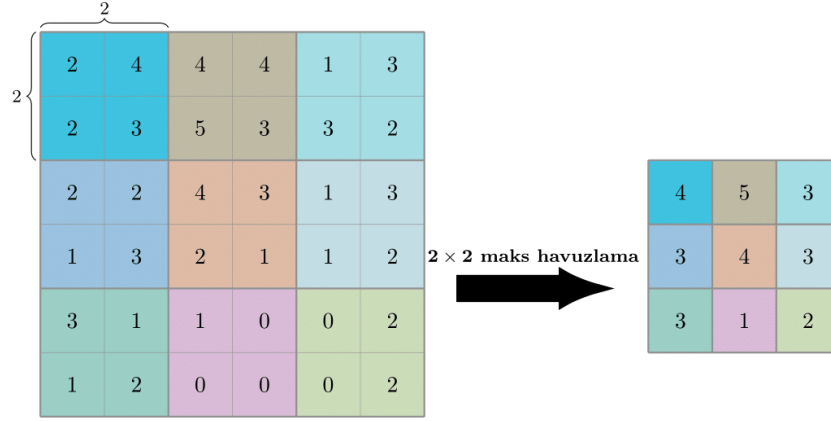
ESA yapısının ilk ortaya atıldığı ve derin öğrenme ile daha da popüler hale geldiği veriler 2 boyutlu tek veya çok kanallı olan görüntü verileri olmuştur. Bu alanlarda büyük gelişmelere öncülük etmiştir. ESA temel yapısı gereği öznelik çıkarım işlemini otomatik hale getirmektedir. Probleme özgü oluşturulan ağlarda evrişim katmanlarında kullanılan süzgeçler eğitim sırasında lokal bölgelerdeki ilgili öznelikleri öğrenmekte ve test sırasında bunları kullanmaktadır. Evrişim katmanlarından oluşan derin sinir ağlarında ilk katmandan son katmana doğru çıkarılan öznelikler düşük nitelikten yüksek niteliğe doğru ilerlemektedir [83]. İki boyutlu verilerde ilk katmanlarda resim işlemede kullanılan standart süzgeçlere benzer yapılar ortaya çıkarken derin kısımlarında ise resimdeki yüksek nitelikleri yakalayan süzgeçler oluşmaktadır. ESA yapısının iki boyutlu verilerde elde ettiği başarımla diğer alanlara da uyarlanmış ve doğal dil işleme [84], konuşma tanıma [85], zaman serilerinin işlenmesi, biyometri [86] ve bölütleme [87] gibi alanlarda sıklıkla kullanılmaktadır.

Evrişimsel Sinir Ağları evrişim katmanı, doğrusal olmayan katman ve havuzlama katmanı olmak üzere 3 bölümden oluşmaktadır. Evrişim katmanında farklı boyutlara sahip süzgeçler giriş verisi üzerinde gezdirilerek evrişim işlemine tabi tutulmaktadır.

Evrişim işleminin seyrek etkileşim ve parametre paylaşımı özelliği sebebiyle önemli değere sahiptir. Böylelikle tam bağlı katmanlardan farklı olarak kullanılan ağırlık katsayıları tüm girdi üzerinde gezdirildiğinden katsayı miktarı oldukça düşmektedir. Aynı katsayıların tüm girdi üzerinde kullanılması ile aynı örüntüye sahip lokal bölgelerdeki öznitelikler keşfedilip öğrenilebilmektedir. Evrişim işleminde kullanılan ağırlık katsayıları çekirdek veya süzgeç olarak isimlendirilmektedir. Bu işlem sırasında adım ve dolgulama işlemleri de bulunmaktadır. Ardından doğrusal olmayan yapıyı sağlamak için ReLU, tanh, sigmoid, vb. aktivasyon fonksiyonu uygulanmaktadır. Kullanılan aktivasyon fonksiyonu ve yapının derinleşmesi ile yüksek nitelikli öznitelikler elde edilmektedir. Katmanın diğer önemli işlemi havuzlama yapısıdır. Bu işlemle birlikte giriş verisinin boyutu düşürülmekte ve daha derin ağların oluşturulması sağlanmaktadır. Bu katmanda boyut küçültme işlemi belirlenen işleme göre yapılmakta ve evrişim ile çıkarılan özelliklerden bir bölümü seçilerek sonraki katmanlara aktarılmaktadır. Sıklıkla kullanılan havuzlama işlemleri maksimum, ortalama ve toplam havuzlama işlemleridir. Havuzlama işleminin olduğu YSA modellerinde bu katmanda eğitim sırasında herhangi öğrenilebilen parametre bulunmamaktadır [88]. ESA yapılarında kullanılan evrişim işlemi ve havuzlama işlemi iki boyutlu veriler için sırasıyla Şekil 2.5 ve 2.6 da gösterilmiştir.



Şekil 2.5 : İki boyutlu bir giriş için evrişim işlemi.



Şekil 2.6 : İki boyutlu bir giriş için maksimum havuzlama işlemi.

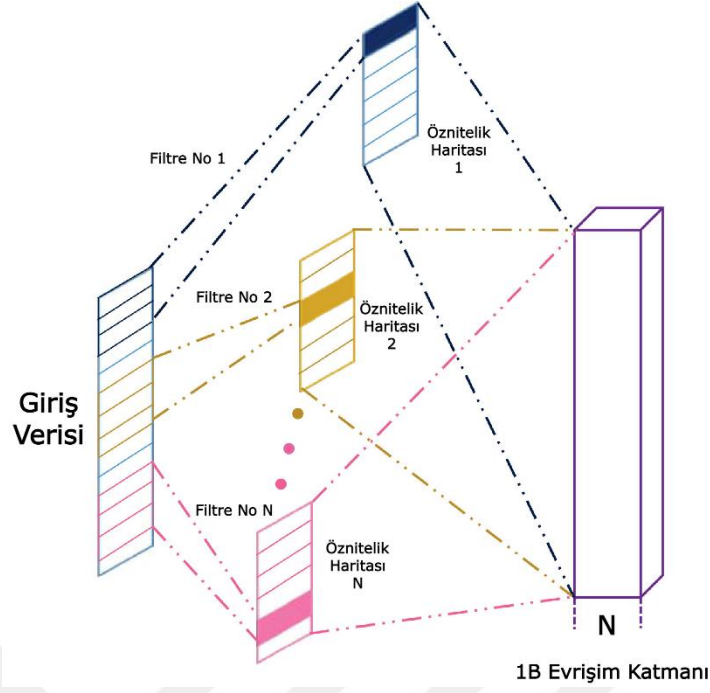
ESA yapısı eğitmek için kullanılan verinin tipine göre değişiklik göstermektedir. Ağ içerisindeki temel işlem olan evrişim işlemi ve havuzlama operasyonu değişmemektedir. Ancak işlemlerde boyutsal olarak değişimler olmaktadır. Ağlar için kullanılan veri tipleri Çizelge 2.2'deki gibidir [83].

Çizelge 2.2 : Veri tipleri.

	Bir Kanallı	Çok Kanallı
1 Boyutlu	Ses dalga formu, sensör verileri	İskelet animasyon verileri
2 Boyutlu	Siyah beyaz resim, spektrogram	Renkli resim
3 Boyutlu	Volumetrik veri, BT verisi	Renkli video

2.3.1 Bir boyutlu evrişimsel sinir ağları

Evrişimsel ağ yapıları özellikle iki boyutlu tek veya çok kanallı veriler üzerinde önerilmiş ve çalışılmıştır. Ayrıca tek boyutlu tek veya çok kanallı verilerde de sıklıkla kullanılmaktadır. Özellikle sensör verilerinin bulunduğu problemlerde bir boyutlu evrişim işlemi otomatik öznitelik çıkarımında kullanılmaktadır. Bu tez çalışmasında bir boyutlu veriler üzerinde çalışılmıştır. Ayrıca kestirimci bakım çalışmaları sistemler üzerindeki sensörlerden gelen verilerin analizi üzerinde yapılmaktadır. Bu sensörler arasındaki farklı zaman noktalarında ve sensörler arasındaki probleme özgü ilişki evrişim işlemi yardımıyla öğrenilebilmektedir. Bir boyutlu evrişim katmanında tasarlanan süzgeçler bir boyutlu olmaktadır. Ancak veriler ise bir boyutlu olmak zorunda değildir. Bir boyutlu evrişim ağının girdi verisi, süzgeçleri ve öznitelik haritasını gösteren grafik Şekil 2.7'de verilmiştir.



Şekil 2.7 : Bir boyutlu bir giriş için bir boyutlu evrişimsel sinir ağı yapısı.

Bir boyutlu evrişim işleminde x bir boyutlu giriş verisini ve w k uzunluklu bir süzgeç vektörünü ifade etsin. Katmanda gerçekleşen evrişim işlemi ve aktivasyon işlemi Denklem 2.3 ve 2.4'te verilmiştir.

$$y = \gamma(x * w + b) \quad (2.3)$$

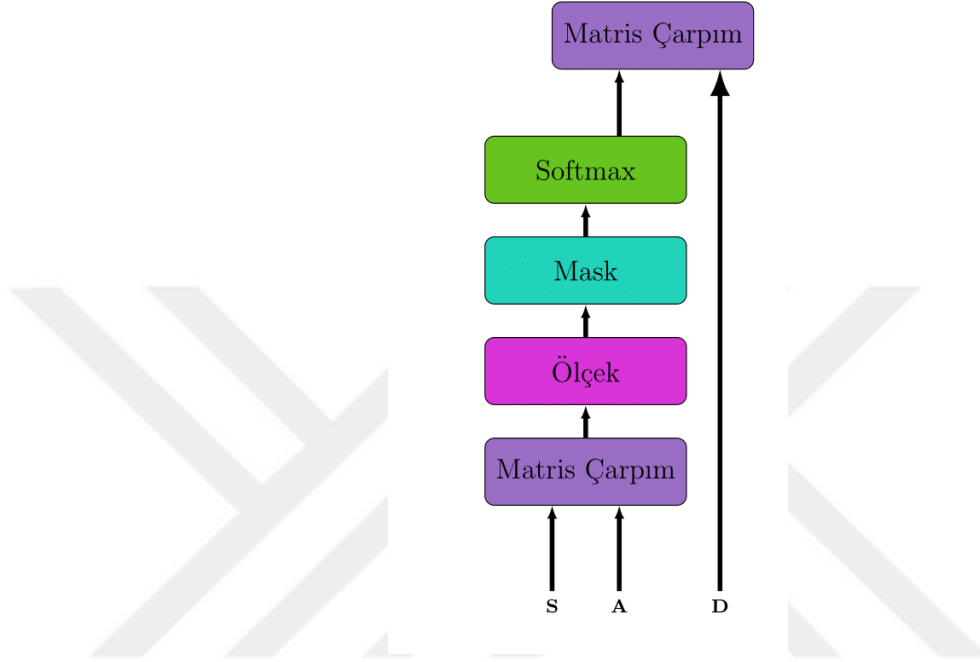
$$y[n] = \gamma \left(\sum_{m=0}^K w[m]x[n + m] + b[n] \right) \quad (2.4)$$

Denklem sonunda oluşan çıkış vektörünün boyutu düşmüş ve tek bir süzgeç ile öznitelik çıkarımı yapılır. Bu katman sonrasında havuzlama işlemi kullanılarak da ağ yapısı derinleştirilir ve daha nitelikli özniteliklerin öğrenmesi sağlanmaktadır.

2.4 Öz-Dikkat Katmanı

Dikkat katmanı sinir ağlarında son zamanlarda sıklıkla kullanılan ve kullanıldığı alanlarda başarılı sonuçlar veren bir yapıdır. Bu katman yapısı insan görme sisteminin çalışma prensibine dayanarak oluşturulmuştur [89]. İnsan görme yapısında bakılan veya incelenen bir resmin anlaşılabilmesi için belirli alanlarına ve önem arz eden alanlarına odaklanılmaktadır. Resim gibi iki boyutlu verilerde derin öğrenme algoritmalarının diğerlerinde bu özellik mevcut değildir. Ayrıca dikkat katmanının

başarımı resim üretiminde, dil çevriminde, nesne tanıma ve üretici dil modellerinde kanıtlanmıştır [90-92]. Dikkat katmanı yapı olarak üç veri girişi ile tek bir çıkış elde edilmesi prensibi ile çalışmaktadır. Şekil 2.8’de klasik bir dikkat katmanının yapısı gösterilmiştir. Bu katmana sorgu, anahtar ve değer olmak üzere üç tane vektör girişi yapılmaktadır.



Şekil 2.8 : Dikkat katmanının genel yapısı.

Literatürde farklı dikkat katmanları bulunmaktadır. Bu yapıları farklılaştıran sorgu, anahtar ve değer vektörlerinin kaynakları olmaktadır. Yapı içerisinde tek bir giriş verisi bölünerek sorgu, anahtar ve değer vektörleri oluşturuluyorsa “Öz-Dikkat” yapısı olarak anılmaktadır. Eğer kaynak veri yapısı farklı girişlerden geliyorsa bu yapı da “Çapraz-Dikkat” olarak anılmaktadır.

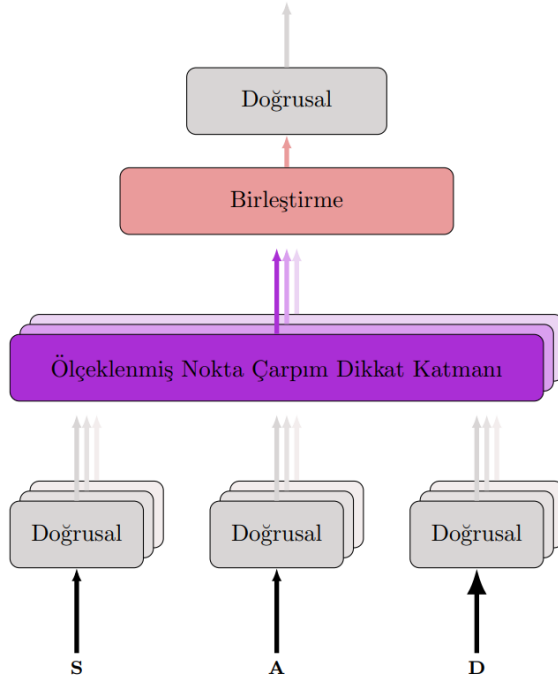
Ayrıca dikkat katmanı yapısı içerisinde kullanılan işlem türüne göre de ayrılmaktadır. Literatürde sıklıkla kullanılan ve dönüştürücü yapısının da temelini oluşturan ölçeklendirilmiş nokta çarpım dikkat katmanı yapısıdır. Bu yapı içerisinde softmax aktivasyon fonksiyonundan önce sorgu ve anahtar vektörleri arasında nokta çarpım yapılmaktadır. Ardından bir ölçekleme değerine bölünmektedir. Bu değer anahtar ve sorgu vektörlerinin boyutları olan d_k değerinin karekökü olarak belirlenmiştir [93]. Sorgu ve anahtar değerlerinin çarpımı sonucu gelen matriste bazı değerlerinin diğerlerine göre çok daha büyük olması softmax sonucu eğitim sırasında çok küçük gradyanlar oluşmasına sebep olabilmektedir. Bu ölçekleme işlemi ile küçük gradyan

problemin önüne geçilebilmektedir. Dikkat katmanının yapısal denklemi Denklem 2.5'te verilmiştir.

$$Dikkat(S, A, D) = softmax\left(\frac{SA^T}{\sqrt{d_k}}\right)D \quad (2.5)$$

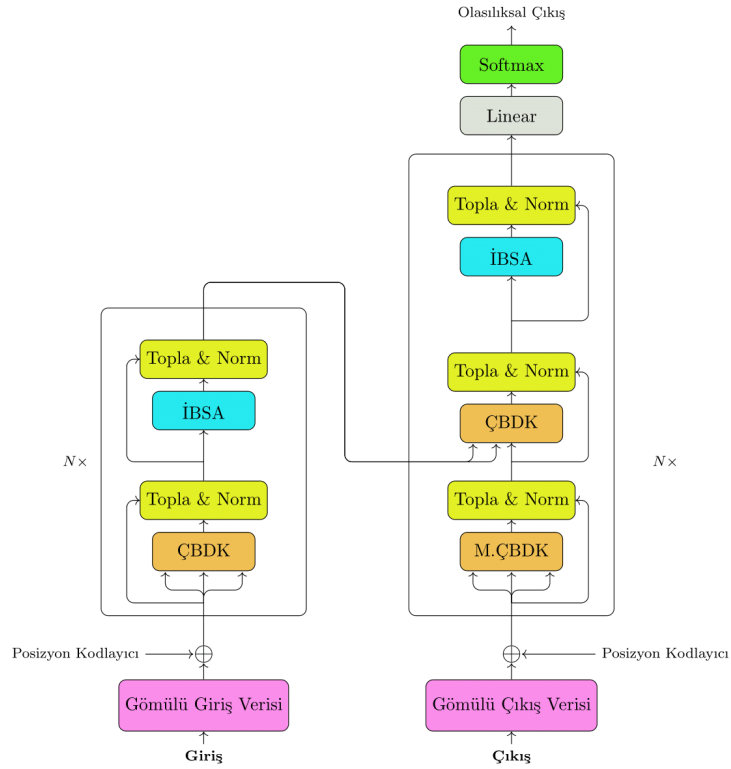
2.5 Dönüştürücü Katmanı

Dönüştürücü yapısı yinelemeli bir sinir ağı yapısıdır. Ancak yinelemeli sinir ağı yapıları sıralı veya zaman serisi şeklinde olan verileri giriş olarak almaktadır. Bu veriler ağ yapısı içerisinde sırayla işlemekte ve ağırlık katsayılarını güncellemektedir. Hem ileri yöndeki ağı yayılımında hem de geri yayılım sırasında sıralı veriler önceki veri noktası işlenmeden sonrasına geçilmesine izin vermemektedir. Bu sıralı yapısı gereği yinelemeli ağlar paralel işlemeye uygun bir yapıda olmamaktadır. Vaswani ve ark. geliştirmiş oldukları kodlayıcı-kod çözücü yapısına sahip dönüştürücü ile paralel işleme probleminin üstesinden gelmişlerdir [93]. Ayrıca dönüştürücü yapısı içerisinde veri noktalarının pozisyon bilgisi kodlanarak girişte işlenebilmektedir [94]. Öz-dikkat katmanına hem kodlayıcı hem de kod çözücü kısmında yer verilerek güçlü bir katman yapısı oluşturulmuştur. Ayrıca Şekil 2.9'da gösterilen çok başlı dikkat katmanı ile sistem hem paralelleştirilmekte hem de farklı sorgu, anahtar ve değer vektörleri ile farklı uzaylardan sonuçlar üretilebilmektedir. Vaswani ve ark. önermiş oldukları dönüştürücü yapısı Şekil 2.10'da gösterilmektedir.



Şekil 2.9 : Çok başlı dikkat katmanı yapısı [93].

Bu ağ yapısında öz dikkat katmanı h tane oluşturularak çıkışları birbirine eklenmiştir. Ardından ağırlık katsayıları ile çarpılarak çıkış elde edilmiş ve sonraki katmanlara aktarılması sağlanmıştır.



Şekil 2.10 : Dönüştürücü ağın genel yapısı [93].


Dönüştürücü ağ yapıları kullanılan probleme göre kodlayıcı, kod çözücü ve kodlayıcı-kod çözücü yapısında kullanılabilir. Bu tez çalışmasında da kodlayıcı kısmında faydalanılmıştır.



3. C-MAPSS UÇAK MOTORU VERİSİNDE KALAN FAYDALI ÖMÜR TAHMİNİ VE KESTİRİMCİ BAKIM UYGULAMASI

3.1 Veri Kümesinin Tanıtılması

C-MAPSS uçak motoru veri kümesi NASA Ames Araştırma laboratuvarı tarafından MATLAB Simulink programı üzerinde yapay olarak oluşturulmuştur. Veri kümesi içerisinde farklı çalışma koşullarında motorlar çalıştırılmış ve bu ortamlarda anlık veriler alınarak veri kümesi oluşturulmuştur. Veri kümesinde kullanılan motorların basitleştirilmiş diyagramı Şekil 3.1’de gösterilmiştir. Şekilde gösterilen Fan ve Yüksek-Basınç Kompresörü (High-Pressure Compressor-HPC) elemanlarında arızalar meydana gelecek şekilde motorlar çalıştırılmış ve veriler toplanmıştır.



Şekil 3.1 : C-MAPSS veri kümesinde kullanılan motorların basitleştirilmiş diyagramı [95].

C-MAPSS veri kümesi benzetim ortamında hazırlanırken her bir motor 14 farklı giriş verisi ile kontrol edilmiştir. Bu 14 giriş verisinden biri motora giren yakıt girişini kontrol ederken geri kalan 13 adet giriş verisi ise motora ait 5 farklı döner elemanın (Fan, Low-Pressure Compressor (LPC), High-Pressure Compressor (HPC), High-Pressure Turbine (HPT) ve Low-Pressure Turbine (LPT)) arıza ve bozulmalarını kontrol etmektedir [14]. Giriş verileri değiştirilerek veri kümesinde farklı arıza modları ve farklı çalışma koşulları oluşturulmuştur. Motorları kontrol etmek için kullanılan 14 adet parametre isim ve sembolleri ile birlikte Çizelge 3.1’de verilmiştir.

Çizelge 3.1 : C-MAPSS veri kümesinde motor kontrolleri için kullanılan giriş parametreleri [14].

Sensör İsmi	Sensör Sembolü
Yakıt Akışı	W_f
Fan verimliliği düzenleyici	fan_eff_mod
Fan akışı düzenleyici	fan_flow_mod
Fan basınç oranı düzenleyici	fan_Pr_mod
LPC verimliliği düzenleyici	LPC_eff_mod
LPC akışı düzenleyici	LPC_flow_mod
LPC basınç oranı düzenleyici	LPC_Pr_mod
HPC verimliliği düzenleyici	LPC_eff_mod
HPC akışı düzenleyici	LPC_flow_mod
HPC basınç oranı düzenleyici	LPC_Pr_mod
HPT verimliliği düzenleyici	HPT_eff_mod
HPT akışı düzenleyici	HPT_flow_mod
LPT verimliliği düzenleyici	LPT_eff_mod
LPT akışı düzenleyici	LPT_flow_mod

Veri kümesi oluşturulurken benzetim üzerinde her biri motoru izlemek için 58 adet sensör kullanılmıştır. Bu sensör verilerinden 21 adeti veri kümesine dahil edilmiş geri kalan veriler eklenmemiştir. Her bir motora ait bozulma modelleri motoru izleyen 21 adet sensör ve çevre koşullarını veren üç adet sensör ile modellenmesi beklenmiştir. Literatürde yapılan çalışmalarda ise sadece 21 adet sensör verisi üzerinden modeller geliştirilmiştir. Motorların çalışma anındaki durumlarını izleyen sensörler ve birimleri Çizelge 3.2’de verilmiştir.

Çizelge 3.2 : C-MAPSS veri kümesi oluşturulurken kullanılan sensörler [14].

Sembol	Tanımı	Birimi
T2	Fan girişindeki toplam sıcaklık	°R
T24	LPC çıkışındaki toplam sıcaklık	°R
T30	HPC çıkışındaki toplam sıcaklık	°R
T50	LPT çıkışındaki toplam sıcaklık	°R
P2	Fan girişindeki basınç	psia
P15	Baypas kanalındaki toplam basınç	psia
P30	HPC çıkışındaki toplam basınç	psia
Nf	Fiziksel fan hızı	rpm
Nc	Fiziksel çekirdek hızı	rpm
epr	Motor basınç oranı (P50/P2)	--
Ps30	HPC çıkışındaki statik basınç	psia
phi	Yakıt akışının Ps30’a oranı	pps/psi
NRf	Düzeltilmiş fan hızı	rpm
NRc	Düzeltilmiş çekirdek hızı	rpm
BPR	Baypas oranı	--
farB	Yakıcı yakıt-hava oranı	--

Çizelge 3.2(devam): C-MAPSS veri kümesi oluşturulurken kullanılan sensörler [14].

Sembol	Tanımı	Birimi
htBleed	Akış entalpisi	--
Nf_dmd	İstenen Fan hızı	rpm
PCNfR_dmd	İstenen düzeltilmiş fan hızı	rpm
W31	HPT soğutma sıvısı sızıntısı	lbm/s
W32	LPT soğutma sıvısı sızıntısı	lbm/s

Veri kümesi dört farklı alt veri kümesinden oluşmaktadır. Her bir alt veri kümesinde ise farklı bir senaryo mevcuttur. Bu senaryolar çalışma koşullarının değiştirilmesi veya arıza modlarının değiştirilmesi ile oluşturulmaktadır. Altı farklı çalışma koşulları ise motorların deniz seviyesi ile 40000 ft. arasında, 0 ile 0.84 Mach hızları arasında ve gaz kelebeği çözümleyici açısının 20 ile 100 derece değiştirilmesi ile farklılık göstermesinden oluşmaktadır. Li ve ark. yaptıkları çalışmada FD004 alt veri kümesi için altı farklı çalışma koşulunun detaylarını vermişlerdir [32]. Bu çalışma koşulları ve detayları Çizelge 3.3'te belirtilmiştir.

Çizelge 3.3 : FD004 alt veri kümesi için altı farklı çalışma koşulu detayı.

Çalışma Koşulları	Rakım (Kft.)	Mach	Gaz Kelebeği Çözümleyici Açısı(derece)
1	42	0.84	100
2	35	0.84	100
3	25	0.62	60
4	20	0.70	100
5	10	0.25	100
6	0	0	100

Arıza modlarında ise HPC ve fan döner ekipmanlarının tek başına veya birlikte kullanılması ile bozulma senaryoları oluşturulmaktadır. Çevre koşullarının ve arıza modlarının değişmesi, ayrıca giriş parametrelerinin farklılaşması ile her bir motorun çalışma ömrü değişiklik göstermektedir. Toplanan verilerde her bir motorun belirlenen çevre koşullarından anlık alınan verilerden oluşmaktadır. C-MAPSS ve alt veri kümelerinin özeti Çizelge 3.4'te verilmiştir.

Çizelge 3.4 : C-MAPSS veri kümesinin detayları.

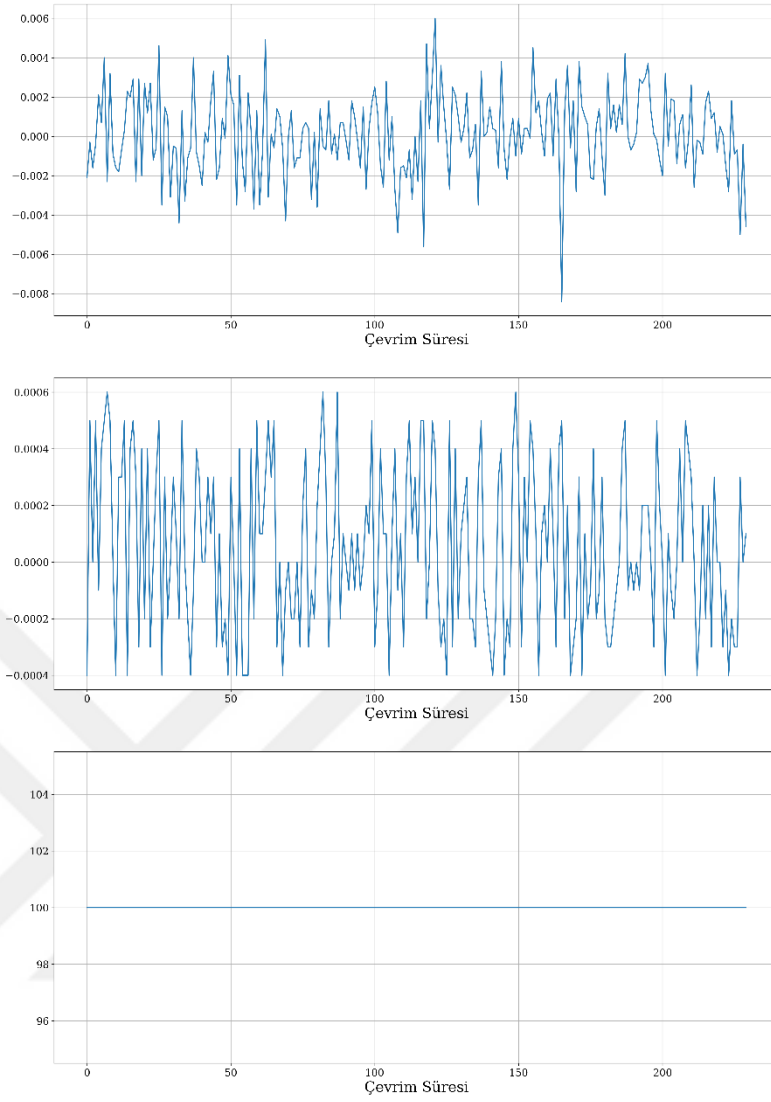
Veri kümesi	NASA C-MAPSS			
	FD001	FD002	FD003	FD004
Eğitim veri kümesi	100	260	100	249
Test veri kümesi	100	259	100	248
Çalışma koşulları	1	6	1	6
Arıza Koşulları	HPC	HPC	HPC,Fan	HPC,Fan

Çizelge 3.4(devam): C-MAPSS veri kümesinin detayları.

Veri kümesi	NASA C-MAPSS			
	FD001	FD002	FD003	FD004
Eğitim veri kümesi örnek sayısı	20631	53759	24720	61249
Eğitim veri kümesindeki Min/Maks döngüler	128/362	128/378	145/525	128/543
Test veri kümesindeki Min/Maks döngüler	31/303	21/367	38/475	19/486


3.2 Önışleme

Kalan Faydalı Ömür kestiriminde bu tez kapsamında ilk olarak C-MAPSS uçak motoru veri kümesi kullanılmıştır. Veri kümesinde motorlarını durumunu takip eden 21 adet sensör, çevre koşullarını izleyen üç adet sensör, motorları ve zamanlarını takip eden iki adet sütun verisi olmak üzere toplam 26 adet sütun verisi bulunmaktadır. C-MAPSS veri kümesine ait özet bilgiler Çizelge 3.4'te verilmiştir ve bu çizelgeye göre FD001 alt veri kümesi modellerin test edildiği en basit senaryoya sahip iken iki farklı arıza modu ve altı farklı çalışma koşulu ile FD004 alt veri kümesi en karmaşık senaryoya sahiptir. FD001 veri kümesinde bulunan 25 numaralı motora ait çalışma koşullarını ifade eden üç adet sensör verisinin grafiği Şekil 3.2'de verilmiştir. Bu grafiklerde y eksenini sensörlerden alınan genlik değerini göstermektedir.



Şekil 3.2 : FD001 25'nolu motora ait çalışma koşullarının sensör verileri.

Motoru izleyen sensör verileri farklı aralıklarda değerlere sahip olabilmektedir. Ayrıca sensörlerden bazıları zamanla değişen bir yapıya sahipken bazı sensörler ise motorun çalışmasından arıza zamanına kadar değerlerinde değişim göstermemektedir. FD001 alt veri kümesinde bulunan 25 numaralı uçak motoruna ait 21 adet sensör verisi Şekil 3.3'te gösterilmektedir. Şekil 3.3'teki grafiklerde y eksenindeki değerler Çizelge 3.2'de verilen sensörlerin birimleri cinsinden genlik değerini ifade etmektedir. Ayrıca x eksenini ise çevrim süresini göstermektedir.



Şekil 3.3 : FD001 25'nolu motora ait çalışma koşullarının sensör verileri.

Motorları izleyen sensör verileri farklı aralıklara sahip olması sebebiyle KFÖ kestirimi sırasında bir sensörün diğerine baskın gelme durumu ortaya çıkmaktadır. Sensörlerin kestirime olan baskınlıklarının eşitlenmesi için normalize edilmesi gerekmektedir. Bu çalışma kapsamında Denklem 3.1'deki z-skor normalizasyon yöntemi ile veriler normalize edilmişlerdir.

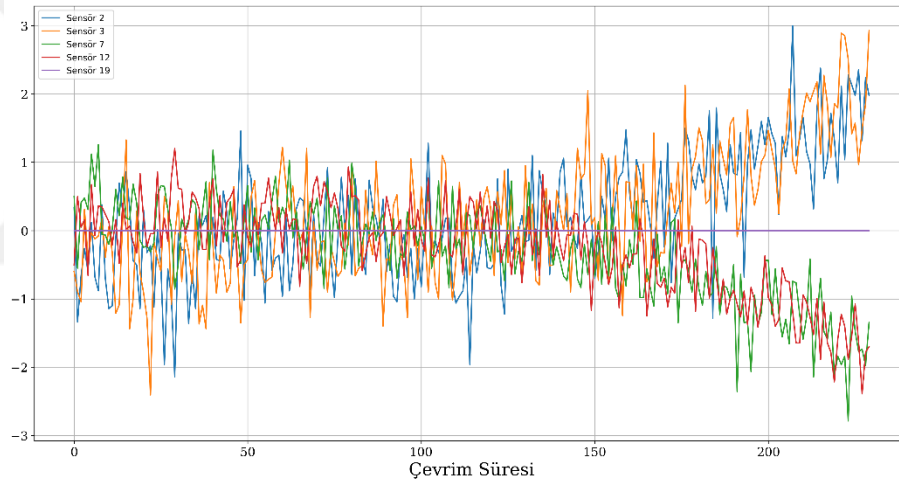
$$\hat{x}_i = \frac{x_i - \mu_i}{\sigma_i} \quad (3.1)$$

Denklem 3.1'de verilen μ_i ifadesi i. sensörün ortalama değerini, σ_i değeri ise o sensörün standart sapmasını temsil etmektedir. Denklem 3.1 yardımıyla her bir sensör normalize edilmiş olur. Ancak sensör değerlerinden bazıları tüm motorlar için zaman boyunca ya hiç değişmemekte ya da çok küçük bir değişiklik olmaktadır. Bu sensörlerin varyans değerleri 0 ya da çok küçük değerli olmaktadır. Denklemdeki σ_i değerinin 0 olması ile tanımsız hale gelen sensörler için bu değerler sabit bir sayıya atanmıştır. Önerilen modelin eğitiminde bir etkisi olmaması için bu sensör değerleri normalize edilirken 0 olarak değiştirilmiştir. Normalize edilmiş sensörler aynı grafik üzerinde birlikte çizdirilmiş ve Şekil 3.5'te gösterilmiştir. Ayrıca sensör değerleri

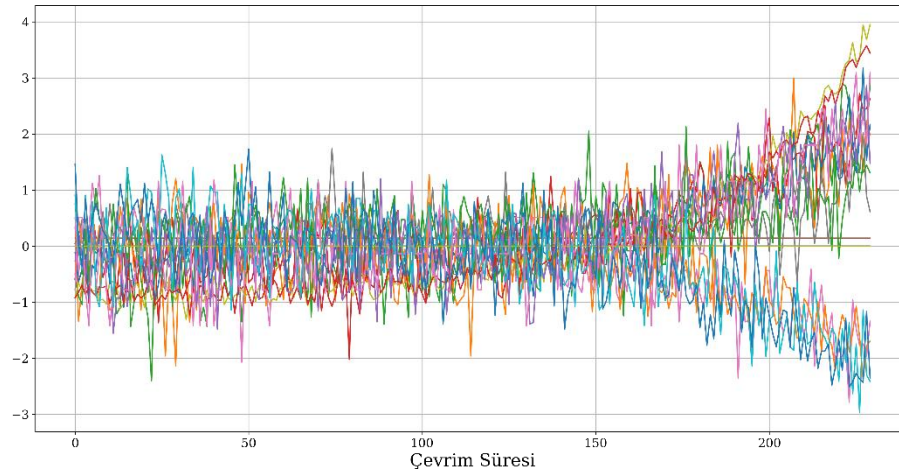
ömürleri boyunca farklı davranışlar sergilemektedir. Bazı sensör değerleri ömürlerinin sonuna doğru değerleri artış gösterirken bazılarının da değerlerinde azalma meydana gelmektedir. Bazı sensör değerleri ise normalizasyon işleminde olanlar gibi ya hiç değişiklik göstermemektedir ya da düzensiz değişikliklere sahiptir. Çizelge 3.9’da sensörler zaman eğilimlerine göre ayrılmış halde verilmiştir [96]. Normalize edilmiş sensör verilerindeki eğilimlere sahip değerler Şekil 3.4’te gösterilmiştir. Böylelikle kestirim modeli eğitimi sırasında bir sensörün diğerine baskın gelmesi önlenmiş olur.

Çizelge 3.5 : C-MAPSS veri kümesindeki sensörlere ait eğilim kategorisi.

Eğilim	Sensör Numarası
Artan Eğilim	2,3,4,5,9,11,13,15,17
Azalan Eğilim	7,12,20,21
Sabit ya da Düzensiz Eğilim	1,5,6,10,14,16,18,19

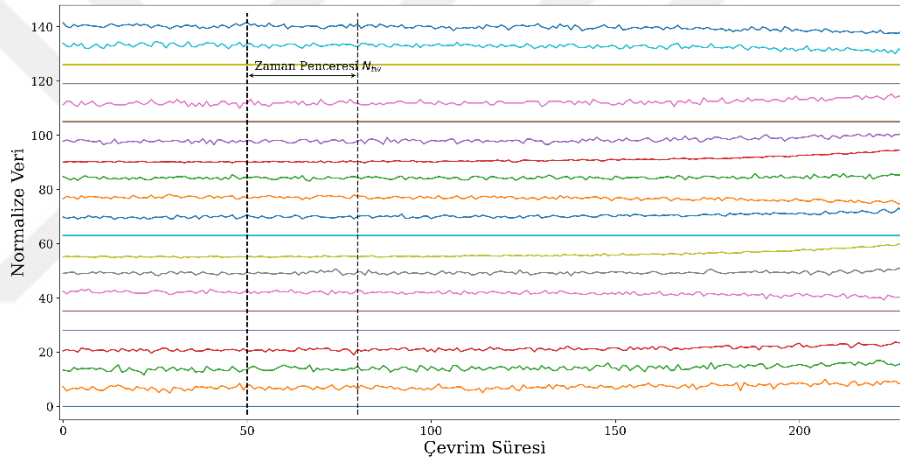


Şekil 3.4 : FD001 25’olu motora ait normalize edilmiş sensör verilerindeki farklı eğilimli sensörler.



Şekil 3.5 : FD001 25’olu motora ait normalize edilmiş sensör verileri.

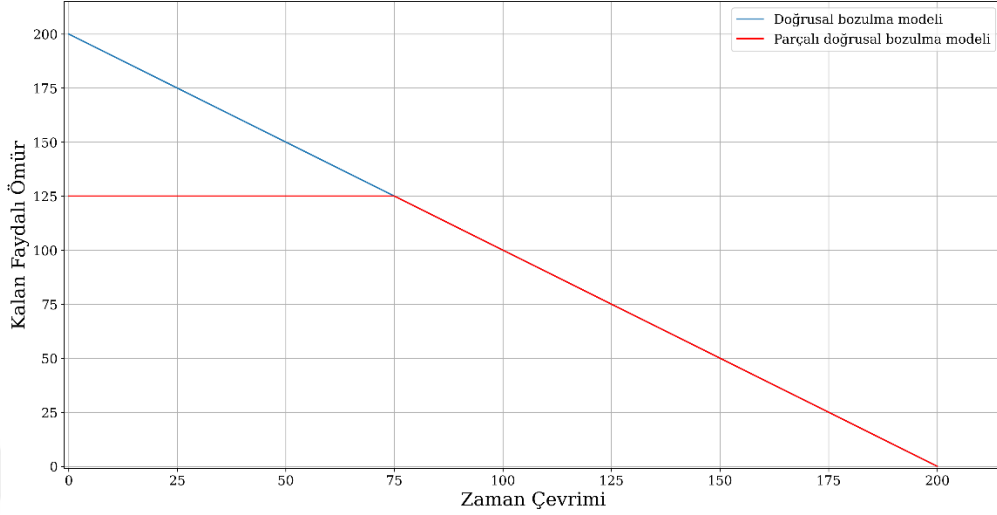
Uçak motoru veri kümesindeki sensör değerleri zaman serileri olarak bulunmaktadır. Verilerin işlenmesinde geçmişe dair verilerin kestirimde etkisini inceleyebilmek için önişleme tabii olması gerekmektedir. Dinamik sinir ağlarının daha iyi kestirim yapabilmesi için zaman uzayında geçmişe ait veriler birlikte giriş olarak verilmelidir. Ayrıca önerilen model yapısında da geçmişe ait sensör değerlerin birbirleri arasındaki ilişkinden kestirim yapılabilmesi planlanmıştır. Bu sebeple Kayan Zaman Penceresi önişleme metodu kullanılarak her bir motor için veri kümesi tekrardan oluşturulmuştur. Veri kümesi oluşturulurken zaman uzayında boyutu belirlenen pencereler birer adım ile kaydırılarak yeni veri kümesi oluşturulmuştur. Böylelikle gelen her bir veri noktası için yeni bir kestirim yapılabilmektedir. Kayan zaman penceresinin bir motorun sensör verileri üzerindeki gösterimi Şekil 3.6'da gösterilmektedir.



Şekil 3.6 : Bir uçak motoru verisinde kayan zaman pencere yönteminin gösterimi.

Gerçek dünya KFÖ problemlerinde sistemlerin bozulmaları anlık çalışmalarından ve ömürlerinden bir eksilmeleri ile gerçekleşmektedir. Bu sebeple doğrusal bozulma modeli ile ömürleri ve bozulmaları modellenmektedir. Literatürde de birçok ömür kestirim problemlerinde çalışmalar doğrusal bozulma modeline göre yürütülmektedir. Sistemlerin ömürleri her bir çalıştırma ile bir azalmakta ve doğrusal yapısını korumaktadır. Ancak üzerinde çalışılan sistemlerde sensörlerin davranışları incelenmekte ve başlangıç süreçlerinde sensörlerde büyük bir değişiklik meydana gelmemektedir. Sistemlerin bozulmaya yakın süreçlerinde ise toplanan sensör verileri başlangıçtaki değerlerine göre hızla değişim göstermektedir. C-MAPSS veri kümesinde sensör değerlerinde bu durum gözlenmektedir. KFÖ kestiriminin daha tutarlı bir yapıda gerçekleşebilmesi için Heimes ve ark. tarafından parçalı doğrusal bir

bozulma modeli önerilmiştir [37]. Literatürde ise hem doğrusal bozulma modeli hem de parçalı doğrusal bozulma modeli farklı çalışmalarda kullanılmıştır. Bu bozulma modelleri birlikte Şekil 3.7’de verilmiştir.



Şekil 3.7 : Doğrusal ve parçalı doğrusal bozulma modelleri.

Şekilde belirtilen parçalı doğrusal bozulma modeli başlangıçta sabit olarak devam etmektedir. Sabit olarak alınan değer R_{early} olarak literatürde geçmektedir. R_{early} ifadesinin değeri C-MAPSS veri kümesi içerisinde en az örneğe sahip veya en az ömre sahip uçak motoruna göre belirlenmiştir. Çizelge 3.4’te görüldüğü üzere alt veri kümeleri incelendiğinde en düşük çevrim süresine sahip uçak motorları 128 çevrim süresi ile verilmiştir. Literatürde bu değeri 120-130 arasında almaktadır. Literatürde yapılan çalışmaların büyük bir bölümü bu değeri 125 olarak almış ve kestirim modellerini buna göre tasarlamıştır [21,39,45]. Bu çalışma kapsamında R_{early} değeri 125 olarak alınmıştır.

PHM 2008 konferansında yayınlanan C-MAPSS veri kümesi katılanların değerlendirileceği metrikler ile birlikte verilmiştir. Bu metrikler kestirim problemlerinde sıklıkla kullanılan KOKH metriği ile probleme özgü yeni bir değerlendirme metriği de sunulmuştur. Bu değerlendirme metriği ile pozitif olan değerler yani kestirilen değer gerçek KFÖ değerinden büyük olması durumunda telafisi olmayan katastrofik arızaların meydana gelmesi muhtemel olduğu için fonksiyon çıkışı daha büyük değerler üretmektedir. Böylelikle pozitif hatalı sonuçları daha büyük cezalandırılması planlanmıştır. Literatür kapsamında kullanılan bu değerlendirme metriklerinin denklemleri aşağıdaki gibidir.

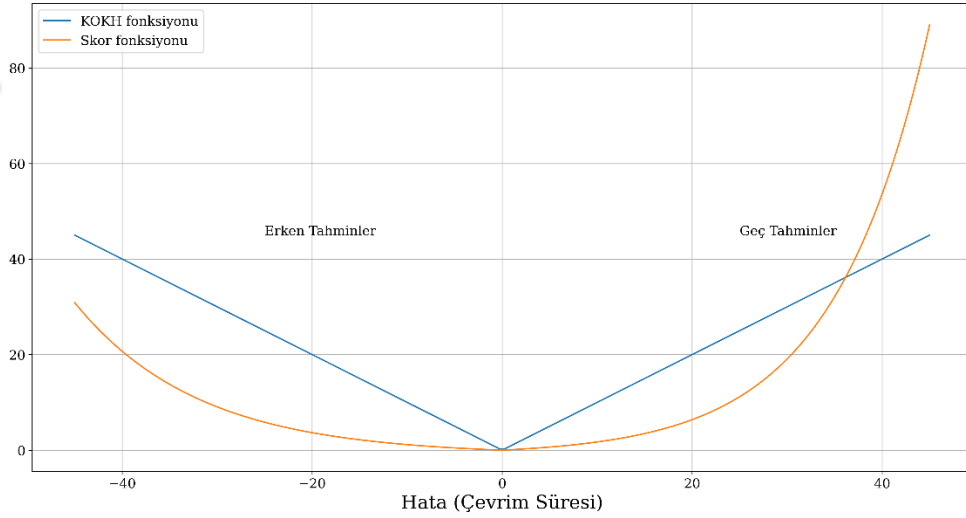
$$d_i = KF\ddot{O}_{kestirim} - KF\ddot{O}_{gercek} \quad (3.2)$$

$$KOKH = \sqrt{\frac{1}{N} \sum_{i=1}^N d_i^2} \quad (3.3)$$

$$S_i = \begin{cases} e^{-\frac{d_i}{13}} - 1, & \text{eğer } d_i < 0 \\ e^{\frac{d_i}{10}}, & \text{aksi durumda} \end{cases} \quad (3.4)$$

$$Skor = \sum_{i=1}^N S_i \quad (3.5)$$

Denklem 3.3 ve 3.5'te verilen N değeri eğitim veya test veri kümesinde bulunan uçak motorlarındaki sayıyı temsil etmektedir. Elde edilen sonuçları değerlendirmek için kullanılan bu iki metriğin karşılaştırmalı grafiği Şekil 3.8'de verilmiştir. Şekil 3.8'de verilmiş grafikte y eksenini çevrim süresini göstermektedir.



Şekil 3.8 : Skor ve KOKH değerlendirme metriklerinin karşılaştırılması.

C-MAPSS veri kümesinde her bir motorun başlangıç parametresindeki değişikliğine göre farklı bir çalışma ömrü bulunmaktadır. Bu çalışma sürecinde eğitim veri kümesindeki tüm motorların 21 adet sensöründen alınan veriler veri kümesinde verilmektedir. Ancak problemin tanımı gereği test veri kümesinde verilen motorların sensör verileri belirli bir noktaya kadar verilmiş ve kestirim modellerinden KFÖ değerini tahmin edilmesi beklenmiştir. Bu değerler ile denklemlerde verilen

değerlendirme metriklerine göre kestirim modelinin başarısı ölçülmektedir. Literatürde yapılan çalışmalarda farklı modeller ile sonuçlar elde edilmiştir.

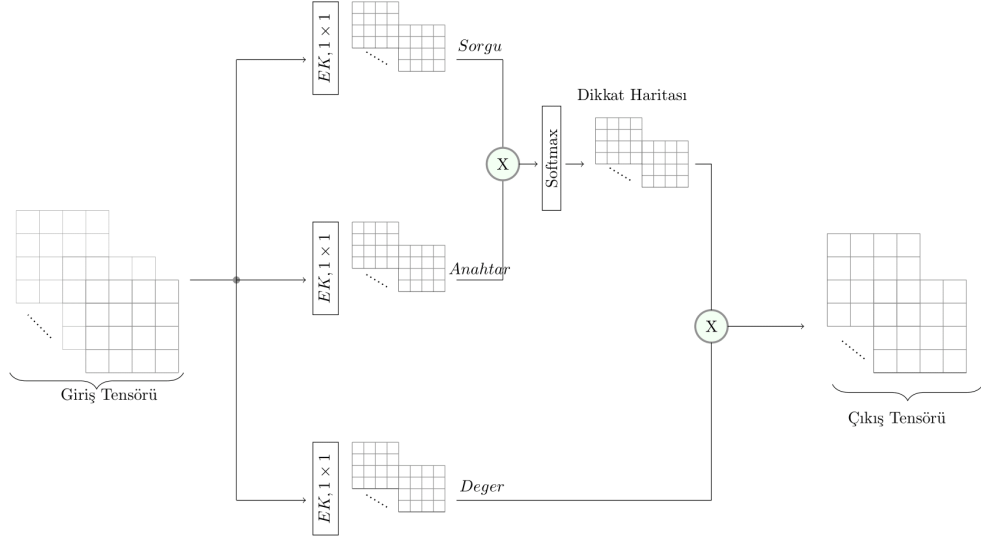
3.3 Önerilen Model ve Sonuçları

Bu tez çalışmasında C-MAPSS veri kümesi üzerinde yapılan kestirim problemi için derin öğrenme yöntemleri kullanılarak veri temelli bir model sunulmuştur. Bu model kapsamında daha iyi kestirim yapılması amacıyla farklı işlevleri olan katmanlar bir arada kullanılmıştır. C-MAPSS veri kümesi içerisinde bulunan alt veri kümeleri Çizelge 3.4'te gösterildiği gibi minimum zaman döngü sayıları farklı olduğundan önerilen modelin giriş katman boyutları da farklılık göstermektedir.

Öncelikle veri kümesinden uçak motorlarını izleyen 21 adet sensörün tamamı kestirim probleminde kullanılmak üzere seçilmiştir. Literatürde yapılan çalışmalarda 21 adet sensörden zamanla değişmeyen ya da düzensiz değişiklik gösteren yedi adet sensör kestirim çalışmasında katkı sağlamayacağı görüşüyle kullanılmamıştır. Ancak bu çalışmada yapılan ön denemelerde tüm sensörlerin kullanımı ile daha iyi sonuçlar alındığı için tüm sensörler kullanılmıştır. Ayrıca önerilen derin öğrenme modelinde ilk katmanlarında bu sensör değerleri ağırlık katsayıları ile çarpıldıktan sonra ilk iki katmandan sonra farklı etkilerle sonraki katmanlara aktarılmaktadır. Normalizasyon sonrasında sıfır değerini alan bu sensörler model içerisinde özellikle evrişim katmanlarında genişleme etkisi görmektedir. Ardından veriler eğitime uygun hale getirilmek için z-skor normalizasyon işlemi ile normalize edilmiştir. Böylelikle her bir sensör verisinin sonuca olan katkısının eşitlenmesi amaçlanmıştır. Verilerde önerilen modele uygun hale getirilmek ve geçmişe dair verilerin de etkisini incelemek için kayan zaman penceresi tekniği kullanılmıştır. Böylelikle her bir alt veri kümesi işlenmeye hazır hale getirilmiştir. Ancak veri kümelerindeki uçak motorların minimum ömürlerinin farklı olması sebebiyle her bir alt veri kümesinin yeni boyutları farklı olmuştur. Elde edilen sonuçların literatürle karşılaştırılabilmesi ve tüm motorların kullanımı için uygun pencere boyutları seçilmiştir. FD001 ve FD003 veri kümeleri için 30 çevrim uzunluklu pencere boyutu seçilirken, FD002 için 21 ve FD004 için 19 çevrim uzunluklu pencere boyutu seçilmiştir. Kayan zaman pencere işlemi hem eğitim hem de test veri kümesi için uygulanmıştır. Her bir motor için KFÖ parçalı doğrusal bozulma modeli ile etiketleme işlemi de yapılarak veri kümesi modeli eğitilmek için hazır hale getirilmiştir.


Kestirim probleminde kullanılmak üzere Öz-Dikkat ve Artık katmanları barındıran Kaskad Öz-Dikkat Artık Ağı (KÖDAA) (Cascaded Self-Attention ResNet Network-CSARN) modeli önerilmiştir. Önerilen modelin giriş katmanı her bir alt veri kümesi için değişiklik göstermektedir. Giriş katmanından sonra Gauss gürültü katmanı kullanılmıştır. Bu katman ile düzenleştirme işlemi modele uygulanmaktadır. Giriş katmanından hemen sonra kullanılarak giriş verilerine ortalaması 0 ve standart sapması 0.01 olan Gauss gürültüsü eklenmektedir. Bu katman sadece modelin eğitiminde kullanılmakta ve modelin verileri ezberlemesinin önüne geçmesini amaçlamaktadır.

Bu çalışmada Bölüm 2’de anlatılan Öz-Dikkat katmanından farklı bir yapıya sahip Öz-Dikkat yapısı sunulmuştur. Standart dikkat katmanında olan sorgu, anahtar ve değer matrislerinin oluşturulması bu katman içinde yapılmıştır. Önerilen katmanda tek bir kaynak, girişten üç farklı matris oluşturulmuştur. Bu yeni matrisler oluşturulurken standart yapıda kaynağın her bir değeri farklı bir ağırlık katsayısı ile çarpılarak elde edilmektedir. Önerdiğimiz yeni Öz-Dikkat katmanında, ağırlık katsayı miktarını azaltmak için kaynağın her bir kanalını farklı bir ağırlıkla evrişim katmanı ile yeni matrislerin oluşturulması sağlanmaktadır. Bu evrişim işleminden sonra “sigmoid” aktivasyon fonksiyonu kullanılmakta ve böylelikle yeni matrislerin değerleri 0 ile 1 arasında sıkıştırılmaktadır. Aktivasyon fonksiyonu sayesinde “softmax” öncesinde değerler normalize edilmektedir. Elde edilen sorgu ve anahtar matrisleri birbiriyle çarpılıp “softmax” aktivasyon fonksiyonundan geçirilerek dikkat haritası oluşturulmaktadır. Bu harita ile elde edilen değer matrisinin hangi noktalarına bakılması ve sonraki katmanlara aktarılması gerektiği belirlenmektedir. Katman çıkışında değer matrisi ve dikkat haritası çarpılarak önerilen Öz-Dikkat katmanının çıkışı oluşturulmaktadır. Bu katman yapısı Şekil 3.9’da gösterilmektedir.



Şekil 3.9 : KFÖ kestirim modelinde kullanılmak üzere önerilen öz-dikkat katmanı.

Derin sinir ağlarında katman sayısı arttıkça ve model derinleştikçe model sonunda hesaplanan hatanın geri yayılım algoritması ile ilk katmanlara etki etmesi zorlaşmaktadır. Bu sorunun çözülmesi için He ver ark. Artık Katman yapısını önermişlerdir [97]. Bu yapı ile ileri beslemeli sinir ağı oluşturulmasında katman içerisinde ikiye ayırım yapılmaktadır. Bir yol boyunca ilgili katman işlemleri yapılırken diğer yol boyunca çok daha az işlem yapılmakta veya hiç işlem yapılmadan ilerlemektedir. Bu iki ayrı yol toplama işlemi ile birleştirilerek sonraki katmanlara bilgi aktarılması yapılmaktadır. Bu çalışma kapsamında Artık Katmanın farklı bir versiyonu önerilmiş ve modelde kullanılmıştır. Önerilen katman yapısı Şekil 3.10'da gösterilmiştir. Artık katman yapısında ilk evrişim katmanı ile kanal sayısı iki katına çıkarılmakta ve ardından tekrar giriş verisinin kanal sayısına düşürülmektedir. İşlem yapılmadan ilerleyen yol ile geri yayılımdaki hatanın ilk katmanlara ulaşması sağlanmış olmaktadır.




Şekil 3.10 : KFÖ kestirim modelinde kullanılmak üzere önerilen resnet katmanı.

KFÖ kestirimi için önerilen model yapısında Evrişimsel Sinir Ağları katmanları da bulunmaktadır. Bu katmanlar ile mekansal özneliklerin çıkarılması hedeflenmiştir. Önerilen model kapsamında evrişim katmanlarında kullanılan süzgeç miktarı sabit tutulmuştur. Son evrişim katmanına kadar her katmanda 10 adet süzgeç kullanılmıştır. Toplamda model yapısında dört tane evrişim katmanı bulunmaktadır. Ayrıca bu katmanlarda kullanılan süzgeçler giriş verisini zaman boyutunda taramak amacıyla sırasıyla 11, 7, 7 ve 7 boyutlu olarak ayarlanmıştır. ESA boyut indirgemedede sıklıkla kullanılan havuzlama katmanı bu model yapısında kullanılmamıştır. Ancak boyut indirgeme işlemi evrişim katmanında süzgeçlerin zaman boyutunda 2 adım atlama yapması için ayarlanması ile sağlanmıştır. Ayrıca son evrişim katmanı haricinde kullanılan dolgulama ile evrişim katman çıkışlarının boyutları korunmuştur.

Bu çalışmada kullanılan KÖDAA modelinin yapısı Şekil 3.11’de verilmiştir. Model girişine normalize edilmiş ve kayan zaman pencere işlevi uygulanmış veriler giriş olarak verilmektedir. Giriş verisi sonrasında modelin ezberlemesini engellemek ve genelleştirebilmek için Gauss Gürültü Katmanı kullanılmıştır. Ardından Evrişim katmanı ve Öz-Dikkat katmanı kullanılmıştır. Öncelikle öznelik çıkarımı yapılmış ve her bir öznelik matrisinin ilgili noktalara odaklanması sağlanmıştır. Sırasıyla ResNet ve evrişim katmanı ile ağ derinleştirilmiş ve daha üst düzey özneliklerin öğrenilmesi hedeflenmiştir. Son katmanları TBK yapıları ile oluşturulmuş ve çıkış katmanına bağlanmıştır. Bu katmanlarda sırasıyla 140 ve 90 adet nöron bulunmaktadır. Modelin ezberlemesini önlemek için TBK yapılarının arasına Seyreltme katmanı kullanılmış ve bu katmanlarda nöronların seyreltme oranı 0.3

olarak belirlenmiştir. Ayrıca modelin geliştirilmesi adına her katmandaki ağırlıklar düzenleme işlemine tabi tutulmuştur ve 0.0002 katsayısı ile L-2 normalizasyon yöntemi kullanılarak normalize edilmiştir. Önerilen model yapısında Öz-Dikkat katmanında kullanılan aktivasyon fonksiyonları hariç tüm katmanlarda 'ReLU' aktivasyon fonksiyonu kullanılmıştır. Önerilen modele ait detaylar Çizelge 3.10'da gösterilmektedir.



Şekil 3.11 : KFÖ kestirimi için önerilen model.

KFÖ kestirimi için önerilen KÖZDAA modeli Google tarafından ücretsiz sağlanan Colab ortamında eğitilmiştir. Model eğitimi "adam" optimizasyon algoritması ile yapılmıştır [98]. Model eğitimi için ayrılan eğitim veri kümesi bölünerek eğitim ve doğrulama veri kümesi olarak ayrılmıştır. Eğitimde bulunan verilerin rastgele atanan yüzde yirmisi doğrulama geri kalanı model eğitimi için kullanılmıştır. Ayrıca model katsayıları eğitilirken mini-grup öğrenme yöntemi kullanılmıştır. Eğitim için belirlenen grup boyutu 32 olarak alınmıştır. Modelin yeterli miktarda öğrenbilmesi için eğitim veri kümesini 250 devirde katsayıları güncellenmesi sağlanmıştır. Ancak yapılan ön çalışmalarda görülmüştür ki modelin bu kadar eğitilmesi ezberlemeye yol açmakta ve test veri kümesinde yapılan kestirimler yanlış olmaktadır. Bu sebeple eğitimin bir kurala bağlı olarak durdurulması sağlanmıştır. Bu kural içinde hesaplanan doğrulama hatası bir önceki değerine göre küçük olmadığı durumdan 20 devir sonrası olarak belirlenmiştir.

Çizelge 3.6 : Önerilen CSARN modelinin detayları.

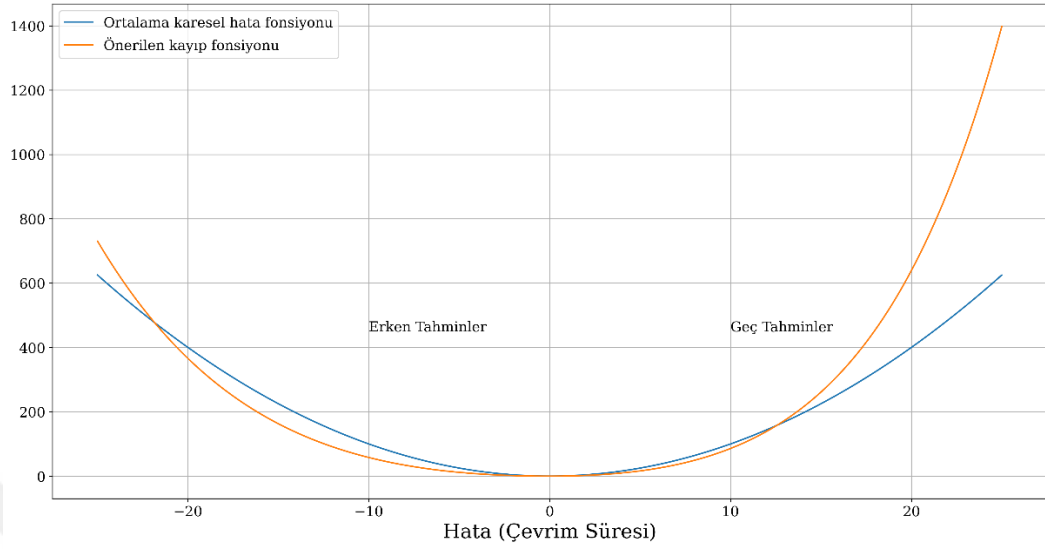
Katman İsmi	Giriş Boyutu	Çıkış Boyutu	Açıklama
Gauss Gürültü Katmanı	30x21x1	30x21x1	Std. değeri = 0.01
Evrişim2B 1	30x21x1	30x21x10	11x1, 10 süzgeç
Öz-Dikkat Katmanı	30x21x10	30x21x10	
ResNet Katmanı 1	30x21x10	30x21x10	
Evrişim2B 2	30x21x10	15x21x10	7x1,2x1 adım,10 süzgeç
ResNet Katmanı 2	15x21x10	15x21x10	
Evrişim2B 3	15x21x10	8x21x10	7x1,2x1 adım, 10 süzgeç
ResNet Katmanı 3	8x21x10	8x21x10	
Evrişim2B 4	8x21x10	2x21x5	7x1, 5 süzgeç
Düzleştirme Katmanı	2x21x5	210	
Seyreltme + Tam Bağlı Katman	210	140	Seyreltme Oranı=0.3
Seyreltme + Tam Bağlı Katman	140	90	Seyreltme Oranı=0.3
Tam Bağlı Katman	90	1	

KFÖ kestiriminde yapılan tahminlerin farklı etkileri bulunmaktadır. Yapılan kestirimle arızanın olması gereken süreden daha sonrası işaret ediliyorsa çalışılan yere göre ölümcül veya maliyeti yüksek sonuçları olabilir. Arızanın daha öncesi kestiriliyorsa gereksiz parça değişimi söz konusu olacaktır fakat daha az maliyetli ve daha güvenli olacaktır. Bu sebeple bu yarışma veri kümesi için Denklem 3.4'te gösterildiği gibi asimetrik bir yapıda değerlendirme metriği önerilmiştir. Önerilen modelin de bu denkleme uygun şekilde eğitilebilmesi için yeni bir kayıp fonksiyonu önerilmiştir. Bu kayıp fonksiyonu ile özellikle belirtilen skor fonksiyonu metriğinde daha iyi sonuçlar elde edilmesi hedeflenmiştir. Böylelikle arızanın beklenenden sonra yapılan tahminlerini önlemek amaçlanmış ve modelin daha güvenilir tahminler yapması istenmiştir. Önerilen skor fonksiyonu Denklem 3.6'da gösterilmektedir.

$$Yeni Kayıp Fonksiyonu = 5 \times \begin{cases} -d_i \times e^{-\frac{d_i}{13}} - 1, & \text{eğer } d_i < 0 \\ d_i \times e^{\frac{d_i}{10}} - 1, & \text{aksi durumda} \end{cases} \quad (3.6)$$

Burada d_i değeri kestirilen KFÖ değeri ile gerçek KFÖ değeri arasındaki farkı göstermektedir. Önerilen kayıp fonksiyonu yardımıyla geliştirilen modelin skor değerlendirme metriğine göre daha iyi sonuçlar elde edecek şekilde eğitilmesi sağlanmıştır. Denkleminde başında belirtilen 5 değeri ise empirik yaklaşımlar sonucunda elde edilmiştir. Önerilen kayıp fonksiyonu ile standart olarak kullanılan

Ortalama Karesel Hata (OKH) kayıp fonksiyonu Şekil 3.12’de gösterilmiştir. Şekil 3.12’de verilmiş grafikte y eksenini çevrim süresini göstermektedir.




Şekil 3.12 : Kayıp fonksiyonlarının karşılaştırılması.

3.4 Deneysel Sonuçların Analizi

Tezin bu bölümünde önerilen KÖDAA modeli ile C-MAPSS veri kümesi üzerinde yapılan çalışmalar anlatılmıştır. Çalışma kapsamında C-MAPSS veri kümesinin dört alt veri kümesi önerilen modelle ayrı ayrı eğitilmiş ve test edilmiştir. Veriler eğitilmeden önce farklı boyutlu kayan zaman pencere tekniği uygulandığından, her bir alt veri kümesi için ağırlık katsayı miktarı ve giriş boyutları farklılık göstermektedir. Uygulanan zaman pencere boyutları FD001, FD002, FD003 ve FD004 için sırasıyla 30, 20, 30, 15 olmuştur. Veri kümesinin eğitim için ayrılan kısmında motorlara ait olan veriler motorun ilk başlangıç verisi ile başlamakta ve arızanın meydana geldiği zamana kadar devam etmektedir. Test için ayrılan verilerde ise sensör verileri belli bir noktaya kadar gelmekte ve arızadan bir süre önce veri alımı kesilmektedir. Bu son noktada motor için istenen KFÖ tahmini yapılması beklenmektedir.

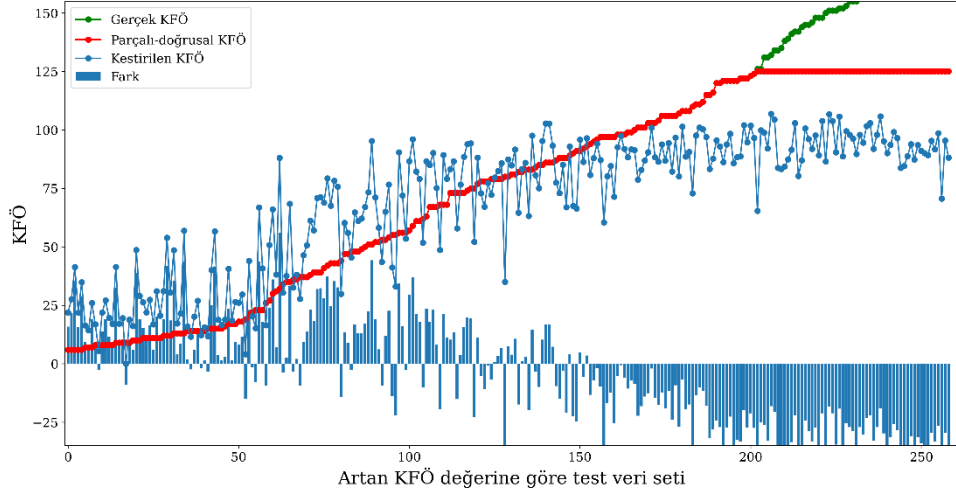
FD001 veri kümesi 100 motor eğitim için 100 motorda test için ayrılan bir veri kümesidir ve diğer alt veri kümeleri ile karşılaştırılırsa en basit senaryoya sahip verilerdir. Önerilen model ile eğitim verisi eğitilmiş ve test veri kümesindeki motorlarda da kestirimler yapılmıştır. Elde edilen kestirim değerleri Şekil 3.13’te verilmiştir. Test veri kümesindeki motorların KFÖ değerlerine göre en küçükten en büyüğe doğru sıralanarak daha iyi bir görsel oluşturulması amaçlanmıştır. Şekil

3.13'te kestirilmesi beklenen gerçek KFÖ değerleri yeşil renkte gösterilmiştir. Veri önışleme sırasında alınan doğrusal parçalı bozulma modeli kabulü ise kırmızı renkli değerler ile ifade edilmiştir. Kestirim modeli bu değerlere göre tahminler yapmış ve ilgili sonuçları elde etmiştir. Şekil 3.13'ten de görüleceği üzere bozulmanın sonlarına doğru yapılan kestirimler daha net sonuçlar vermektedir. Şekil 3.13'teki kestirim değerleri en büyük sapmanın motorların başlangıç ve ömürlerinin ortasına kadarki zaman diliminde olduğunu göstermektedir.



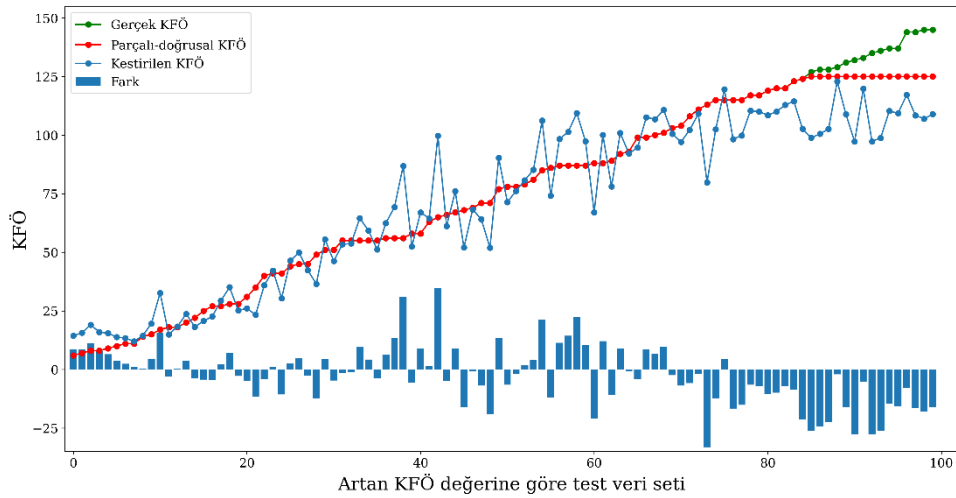
Şekil 3.13 : FD001 test veri kümesindeki tüm motorların KFÖ kestirimi.

FD002 veri kümesi 260'ı eğitim veri kümesinde 259'u test veri kümesinde olmak üzere birçok motorun KFÖ tahmini için verileri toplandığı alt veri kümesidir. Bu veri kümesinde 6 farklı çalışma koşuluna göre veriler üretilmiş ve kestirim için hazırlanmıştır. FD002 test veri kümesinde kestirim yapılacak motorlar arasında en az örneğe sahip motor 21 çevrim süresi sensör verisine sahiptir. Bu sebeple bu alt veri kümesi önışleme sırasında 20 çevrim sürelik pencerelere bölünmüştür. Önerilen modelin giriş değişmiş ve ağırlık katsayı miktarı azalmıştır. Ancak aynı modelin farklı veri kümelerindeki durumunu incelemek için modelin girişinin değişmesi dışında başka bir değişiklik yapılmadan model eğitilmiştir. Elde edilen kestirim sonuçları ile gerçek KFÖ değerleri ve parçalı doğrusal bozulma modeline ait KFÖ değerleri Şekil 3.14'te verilmiştir. Elde edilen sonuçlara göre modelin tam olarak eğitimini tamamlamadığı ya da ezbere gittiği görülmektedir. Bu modelin sonuçlarına göre KFÖ ortalarında daha az hatanın olduğu diğer bölgelerde büyük sapmaların oluştuğu gözlenmektedir. Altı farklı çalışma koşulunda olması sebebiyle ilk alt veri kümesine göre daha büyük farklar oluşmuştur.



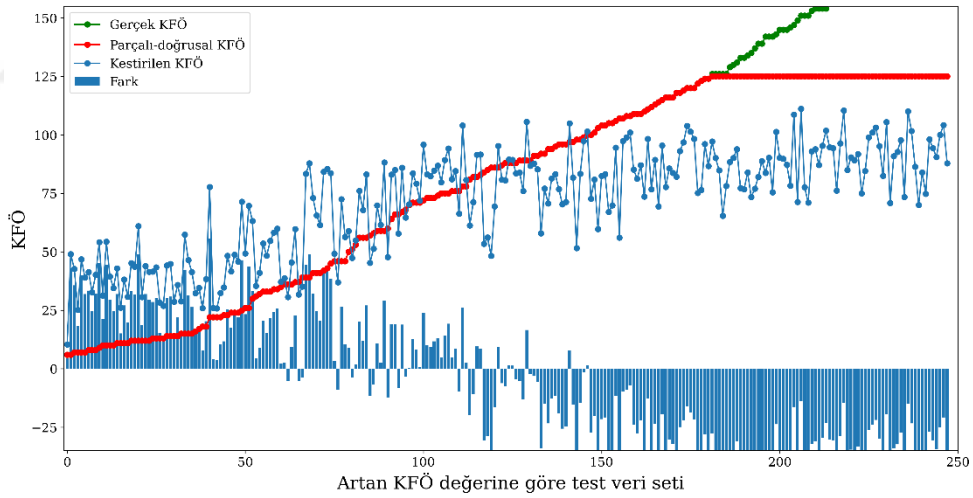
Şekil 3.14 : FD002 test veri kümesindeki tüm motorların KFÖ kestirimi.

FD003 veri kümesi ilk veri kümesinde olduğu gibi 100 motor eğitim veri kümesinde 100 motor test veri kümesinde olacak şekilde üretilmiştir. HPC ve Fan arıza modları ile ilk veri kümesinden farklılık göstermektedir. Bu veri kümesi de sadece tek bir çalışma koşuluna göre hazırlanmıştır. FD003 alt veri kümesinde kayan zaman pencere boyutu literatürle karşılaştırılabilmesi için 30 çevrim süresine göre ayarlanmıştır. Bu sebeple temelde önerilen model yapısı ve ağırlık katsayı miktarı aynı olmuştur. Önerilen model eğitim veri kümesinde eğitilmiş ve test veri kümesinde KFÖ kestirimi yapılmıştır. Yapılan kestirimler, gerçek ve parçalı doğrusal bozulma modeline göre hazırlanmış KFÖ değerleri Şekil 3.15'te verilmiştir. İlk veri kümesinde olduğu gibi motorun çalışmaya başladığı zamanda yapılan kestirimlerin hatası daha büyük olmaktadır. Elde edilen KOKH ile skor fonksiyon değerine göre iki farklı arızanın modellenmiş olması elde edilen değerlerin daha yüksek olmasına sebep olmuştur.



Şekil 3.15 : FD003 test veri kümesindeki tüm motorların KFÖ kestirimi.

FD004 alt veri kümesi hem iki farklı arıza bulundurması hem de altı farklı çalışma koşulunda motorların test edilmesi sebebiyle diğer alt veri kümelerine göre en karmaşık yapıya sahiptir. Bu veri kümesinde 249 adet motor verisi eğitim kümesinde yer alırken 248 motor da test kümesinde yer almaktadır. Test veri kümesinde bulunan motorlardan en az örneğe sahip motor 19 örneklemeden oluşması sebebiyle hem veri önışlemede hem de modelin girişinin ayarlanmasında diğerlerine göre farklılık göstermiştir. Bu model için kullanılan kayan zaman penceresinin çevrim boyutu 15 olarak belirlenmiştir. Bu değer literatürde sıklıkla kullanılan bir değerdir ve böylelikle elde edilen sonuçların karşılaştırmasının daha uygun yapılması hedeflenmiştir. Önerilen model ile elde edilen KFÖ kestirim sonuçları gerçek ve parçalı doğrusal bozulma modeli ile birlikte Şekil 3.16’da verilmiştir. Elde edilen sonuçlar incelendiğinde modelin parçalı doğrusal bozulma modeline yakınsaması diğerlerine göre daha düşük olduğu görülmektedir. Verilerin diğerlerine göre daha karmaşık olması ve eğitim hiper parametrelerinin sabit bırakılması sebebiyle bu sonuçlar elde edilmiştir. Özellikle motorların başlangıç ve bitiş noktalarında kestirim hataları büyük olmaktadır.



Şekil 3.16 : FD004 test veri kümesindeki tüm motorların KFÖ kestirimi.


Önerilen KÖDAA modeli ile C-MAPSS veri kümesinin 4 alt veri kümesi üzerinde yapılan deneyler sonucunda elde edilen sonuçlar Çizelge 3.11’de verilmiştir. Bu çalışma kapsamında öne sürülen yeni kayıp fonksiyonu ile özellikle değerlendirme metriklerinden skor fonksiyonunda daha iyi sonuçlar elde edilmeye çalışılmıştır. Kayıp fonksiyonunun asimetric yapısı sayesinde doğru yapılan kestirimler ile arıza durumunda meydana gelebilecek ölümcül sonuçların önüne geçilmek istenmiştir. Böylelikle her bir motorda kestirim ile skor değerinde daha düşük sonuçlar elde

edilmiştir. Sonuçlar incelendiğinde en basit senaryoya sahip FD001 veri kümesinde literatüre göre de diğer veri kümelerine göre de daha iyi sonuçlar elde edilmiştir. Veri kümesi karmaşıklığı arttıkça hem KOKH değerinde hem de skor fonksiyonu değerlendirme metriğinde sonuçlar artmaktadır. KOKH değerlendirme metriğine göre FD001, FD002, FD003 ve FD004 veri kümelerinde elde edilen sonuçlar sırasıyla 11.017, 23.14, 12.63 ve 26.39'dur. Aynı alt veri kümelerinde skor fonksiyon değerleri sırasıyla 157.19, 2490.09, 218.6, 3800.15 olarak bulunmuştur. Özellikle FD002 ve FD004 veri kümelerinin karmaşık yapısı dışında veriler işlemeye hazırlanırken diğer alt veri kümelerine göre daha az geçmişe yönelik veri saklanarak kestirim yapılmıştır. Zaman serisine sahip verilerde kestirim çalışması yapılırken geçmişe dair verilerin önemi ön plana çıkmıştır.

Çizelge 3.7 : Önerilen CSARN modeli ile elde edilen sonuçlar.

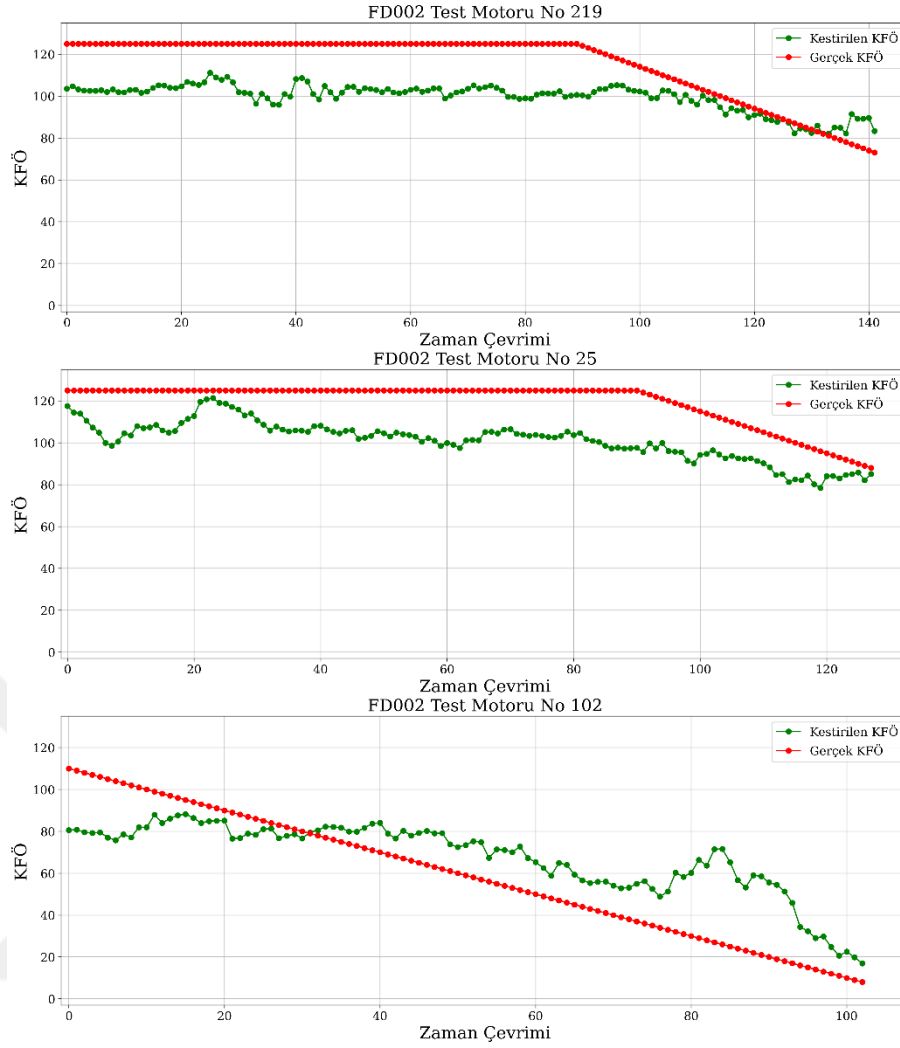
	KOKH	Skor Değeri
FD001	11,017	157,19
FD002	23,14	2490,09
FD003	12,63	218,6
FD004	26,39	3800,15

Önerilen model ile FD001 alt veri kümesi üzerinde yapılan çalışmalarda KFÖ için başarılı sonuçlar elde edilmiştir. Özellikle skor fonksiyonu değerinde literatüre göre en iyi sonuçlar elde edildiği söylenebilmektedir. Bu değerler test veri kümesinde eğitilen modelin her bir motor için çalıştırılması ve KFÖ üretmesi ile olmuştur. Burada elde edilen sonuçlar veri kümesini hazırlayan ekibin rastgele bir noktada veri alımını durdurduğu ve o noktada tahmin beklenildiği kısımlardır. Hazırlanan model ile elde edilen sonuçlarda bir motorun her veri noktası için bir KFÖ üretmesi sağlanmıştır. Şekil 3.17'de test veri kümesindeki motorlardan en iyi sonuçların alındığı üç motorun sonuçları gözükmemektedir. Bu grafiklerde motora ait parçalı doğrusal bozulma modeli ve kestirimi yapılan KFÖ değerleri birlikte verilmiştir. Şekilde görüldüğü üzere önerilen model genel itibari ile bozulma modelini takip etse de özellikle bozulmaya yaklaştığı zaman daha az hata ile sonuçlar vermiştir.



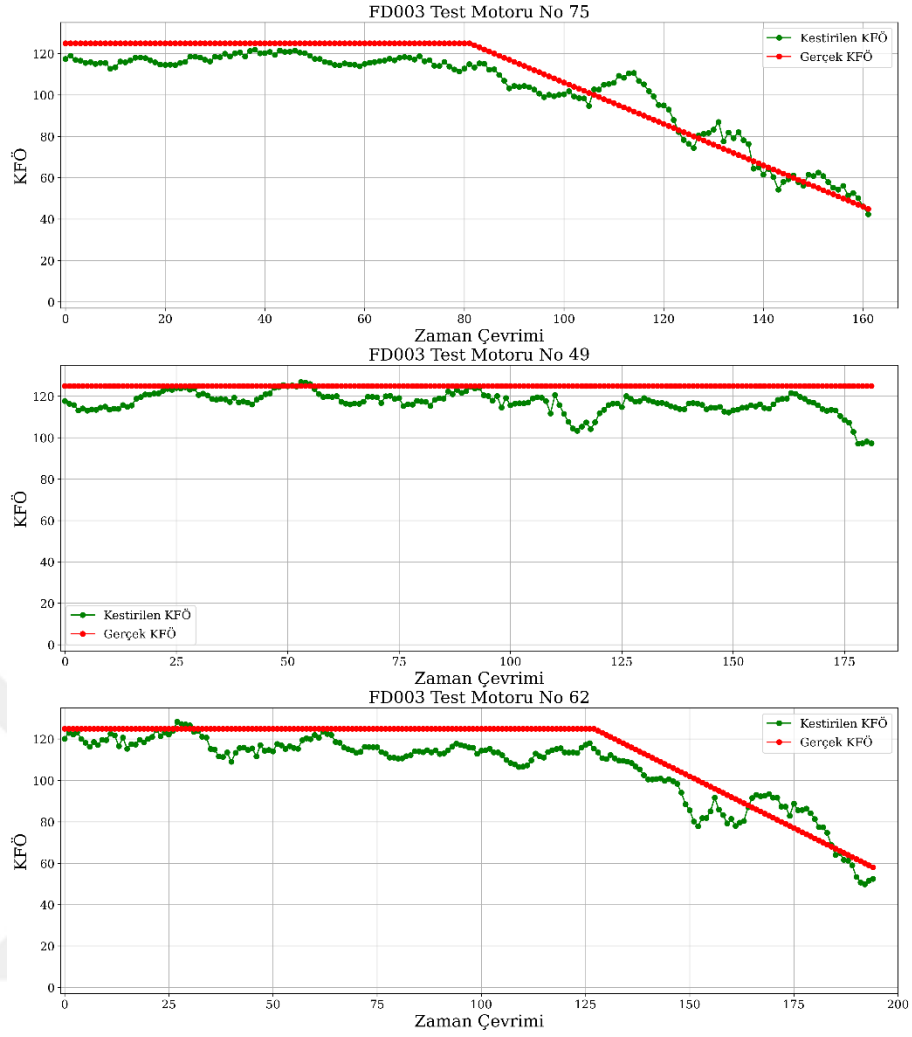
Şekil 3.17 : FD001 test veri kümesindeki en iyi üç motorun kestirim grafiği.

Yapılan çalışmada önerilen model ile FD002 alt veri kümesinde de deneyler yürütülmüştür. Her bir motor için KFÖ hesabı yapılmıştır. Bu hesaplar yapılırken belirlenen zaman penceresi uzunluğu kadarki ilk verilerde kestirim üretilmemiştir. Ardından gerekli tarihsel veri oluştuğundan sonra kestirim yapılmış ve gerçek değerler ile karşılaştırmalı olarak incelenmiştir. FD002 test veri kümesinde yapılan çalışma sonucunda en iyi sonuçları veren üç motor verisi Şekil 3.18’de gösterilmiştir. Grafiklerde parçalı doğrusal bozulma modeli ile kestirimi yapılan KFÖ değerleri birlikte verilmiştir. Grafikler incelendiği zaman ilk veri kümesine göre kestirimlerdeki hata daha büyük olduğu görülmektedir. Genel kestirimler dışında da motor bazlı kestirimlerde de önerilen modelin önerilen eğitim koşullarına göre yeteri kadar öğrenme gerçekleştirmediği söylenebilir. İlk veri kümesinde olduğu gibi, FD002 veri kümesinde de yapılan kestirimler son yarı ömürde daha az hata ile yapıldığı gözlenmiştir.




Şekil 3.18 : FD002 test veri kümesindeki en iyi üç motorun kestirim grafiği.

C-MAPSS veri kümesinin iki hata tek çalışma koşuluna sahip alt veri kümesi olan FD002 veri kümesinde KÖDAA modeli ile eğitim ve kestirim çalışmaları yürütülmüştür. Veri kümesi önışlem kısmı ilk veri kümesi ile aynı olması sebebiyle her bir motor için ilk 30 örnekten sensör verileri alındıktan sonra ilk kestirimler yapılmıştır. Test veri kümesinde her bir motor için kestirimler yapılmış ve en iyi sonuçlara göre ilk üç motorun bozulma grafikleri Şekil 3.19’da verilmiştir. Şekil üzerinde hem parçalı doğrusal bozulma modeline uygun gerçek değerler hem de modelin sensör değerlerine göre yapmış olduğu kestirimler gözükmektedir. İlk veri kümesinde olduğu gibi tek kestirim noktası için tarihsel veriler girişte daha fazla olmasından elde edilen sonuçlar ve izlenen bozulmalar gerçek değerlere daha yakın olmuştur.



Şekil 3.19 : FD003 test veri kümesindeki en iyi üç motorun kestirim grafiği.

Önerilen model ile yapılan çalışmalarda en karmaşık senaryoya sahip FD004 üzerinde kestirimler yapılmış ve her bir motor için sonuçlar elde edilmiştir. Diğer alt veri kümeleri ile karşılaştırıldığında modele alınan veri girişlerinde en az tarihsel bilgi barındıran alt veri kümesidir. Bu sebeple yapılan kestirimlerde daha büyük hatalar alınmıştır. Her bir motor için yapılan kestirimler sonucunda en iyi üç motora ait kestirim grafiği Şekil 3.20’de verilmiştir. Grafikler incelendiğinde motorun başlangıç durumunda yapılan kestirimler gürültü ve farklı çalışma koşullarının da etkili olması ile gerçek değere göre büyük farklılıklar göstermektedir. Motorların ömürlerinin sonlarına yaklaştıkça elde edilen sonuçlar yakınsamış olsa da diğer alt veri kümelerine kıyasla geliştirilmesi gerektiği görülmektedir.



Şekil 3.20 : FD004 test veri kümesindeki en iyi üç motorun kestirim grafiği.

3.5 Ablasyon Çalışmaları ve Sonuçları

C-MAPSS veri kümesi üzerinde yapılan çalışmalarda kestirim sonuçlarını iyileştirmek için farklı katmanlar test edilmiş ve sonuçları incelenmiştir. Önerilen öz-dikkat katmana sahip KÖDAA modeli ile özellikle FD001 alt veri kümesinde iyi sonuçlar elde edilmiştir. Bu çalışma kapsamında ve bu bölüm içerisinde modelde kullanılan katmanların sonuçlara olan etkisi incelenecek ve detaylandırılacaktır. Önerilen modelin sonuçları iyileştirdiği belirtilen ve literatürde farklı ağırlarda etkisini kanıtlamış katmanlar temel model ile birlikte incelenmiştir. Modelde bulunan Gauss Gürültü Katmanı (GGK), tüm ResNet ve Öz-Dikkat Katmanları (ÖDK) çıkarıldıktan sonra geriye kalan Evrişim katmanları ile TBK temel modeli oluşturmuştur. Temel modele her katmanın ayrı ayrı eklenmesi ile sonuca olan katkıları incelenmiştir. Elde edilen sonuçların karşılaştırması yapılırken temel model ve her bir eklenen katmanla oluşan

yeni modellere yeni isimlendirme yapılmıştır. Temel modele CSARN1, GGK eklendiğinde CSARN2, sadece ResNet katmanı eklendiğinde CSARN3, sadece ÖDK eklendiğinde CSARN5 olarak isimlendirilmiştir. CSARN2 modeline ResNet katmanı eklendiğinde CSARN4, sadece ÖDK eklendiğinde CSARN6 olarak isimlendirme yapılmıştır. Temel modele ÖDK ve ResNet katmanı eklemesi yapıldığında CSARN7 olarak anılmıştır. Önerilen modelde ise tüm katmanlar eklenmiş durumdadır ve CSARN olarak çizelgelerde yer almaktadır. Her bir katmanın etkisinin incelendiği bu kısımdaki isimlendirmelerin özeti Çizelge 3.12’de verilmiştir.

Çizelge 3.8 : Önerilen modellerin isimlendirilmesi.

Model İsimleri	Açıklama
CSARN1	Temel Model
CSARN2	Temel Model + GGK
CSARN3	Temel Model + ResNet
CSARN4	Temel Model + GGK + ResNet
CSARN5	Temel Model + ÖDK
CSARN6	Temel Model + GGK + ÖDK
CSARN7	Temel Model + ÖDK + ResNet
CSARN	Temel Model + GGK + ÖDK + ResNet

Önerilen model ile birlikte katmanların etkileri öncelikle FD001 veri kümesi için incelenmiştir. Her bir deneysel çalışma sonucunda modele ait KOKH değeri ile skor fonksiyonu değerlendirme metriği hesaplanmıştır. Her bir model için yapılan deneysel sonuçlar Çizelge 3.13’te verilmiştir. Bu model geliştirilirken kullanılan katmanlar dışında bir de önerilen bir kayıp fonksiyonu da mevcuttur. Katmanların etkisi incelendiği için yeni kayıp fonksiyonu değiştirilmemiştir. Buna göre Çizelge incelendiğinde GGK, Öz-Dikkat katmanı ve ResNet katmanları arasında temel modele eklenip tek başına olumlu etki gösteren Öz-Dikkat katmanı olmuştur. Temel model ile elde edilen hem KOKH değeri hem de skor değeri Öz-Dikkat katmanı eklenince düşmüştür. Yeni oluşan model CSARN5 diğer katmanların eklenmesi ile sonuçların daha da iyileşmesi söz konusu olmamıştır. Ancak tüm katmanlar eklenip önermiş olduğumuz CSARN modeli elde edildiğinde Çizelge 3.13’te görüldüğü gibi en iyi KOKH ve skor değerlerini vermiştir.

Çizelge 3.9 : FD001 veri kümesinde model katmanlarının sonuçlara etkisi.

Model İsimleri	KOKH	Skor Değeri
CSARN1	11,73	181,25
CSARN2	12,85	197,77
CSARN3	12,94	206,51
CSARN4	13,10	217,65
CSARN5	11,36	167,62
CSARN6	11,63	172,50
CSARN7	11,91	189,92
CSARN	11,017	157,19

Yapılan çalışma kapsamında ablasyon çalışmaları önerilen model ile birlikte FD002 alt veri kümesinde de incelenmiştir. Bu alt veri kümesi diğer veri kümesine göre altı farklı çalışma koşulu ile daha karmaşık bir yapıya sahiptir. Temel model ile birlikte diğer katmanlar incelendiğinde değerlendirme metriklerinde KFÖ kestirimleri daha büyük değerler vermişlerdir. Ayrıca FD001 veri kümesi sonuçları ile karşılaştırıldığında bu veri kümesinde katmanların etkilerinin farklılaştığı görülmektedir. Çizelge 3.14’te temel model ve her bir katmanın etkisi KOKH ile skor fonksiyonuna göre verilmiştir. Temel modele eklenen Öz-Dikkat katmanı önerilen KÖDAA yapısına göre de daha iyi sonuçlar vermiştir. Bununla birlikte GGK katmanı tek başına da olumlu katkı yapmıştır. Çizelge incelendiğinde en iyi sonucun temel model üzerine eklenen Öz-Dikkat katmanı ile alındığı görülmektedir.

Çizelge 3.10 : FD002 veri kümesinde model katmanlarının sonuçlara etkisi.

Model İsimleri	KOKH	Skor Değeri
CSARN1	25,68	2810,14
CSARN2	23,69	2632,15
CSARN3	24,93	3206,75
CSARN4	26,11	3325,27
CSARN5	23,47	2268,41
CSARN6	24,35	2693,47
CSARN7	24,76	2856,51
CSARN	23,14	2490,09

FD003 veri kümesi FD001 veri kümesine göre ikinci bir arızaya sahip olması ile arızaya duyarlılık tespitine göre daha karmaşık bir veri kümesidir. Deneysel çalışmalar temel modelden önerilen modele kadar toplam da sekiz farklı yapı ile eğitim veri kümesinde eğitilip test veri kümesinde sonuçlar elde edilmiştir. Tüm modellerin hem KOKH hem de skor fonksiyon değerleri Çizelge 3.15’te verilmiştir. Çizelge incelendiğinde diğer alt veri kümelerinde olduğu gibi Öz-Dikkat katmanı temel modele en çok olumlu katkı yapan katman olmuştur. Bu katkı diğer veri kümelerinde

önerilen kayıp fonksiyonu ile skor değerinde olurken FD003 veri kümesinde KOKH değerinde olmuştur. Önerilen model ise KOKH değerinde daha düşük sonuç verirken skor değerinde temel modele göre daha büyük değerler vermiştir.

Çizelge 3.11 : FD003 veri kümesinde model katmanlarının sonuçlara etkisi.

Model İsimleri	KOKH	Skor Değeri
CSARN1	13,13	210,67
CSARN2	12,73	258,6
CSARN3	14,02	252,16
CSARN4	15,17	263,36
CSARN5	11,94	217,78
CSARN6	12,82	233,71
CSARN7	12,38	210,60
CSARN	12,629	218,6

C-MAPSS veri kümesinin en karmaşık senaryosuna sahip FD004 veri kümesi üzerinde önerilen model dahil sekiz farklı yapı ile ablasyon çalışması yapılmıştır. Her bir katmanın bu alt veri kümesinde etkisi incelenmiştir. Elde edilen sonuçlar Çizelge 3.16’da sunulmuştur. Veri kümesinin senaryo karmaşıklığı ile diğer veri kümelerinde elde edilen sonuçlara göre önerilen katmanların ve modellerin etkileri farklılık göstermiştir. Diğer veri kümelerinde özellikle Öz-Dikkat katmanı olumlu yönde katkı sunarken bu veri kümesinde tek başına kullanıldığında olumlu bir katkı gözlenmemiştir. Ancak önerilen model KÖDAA yapısı hem KOKH değerinde hem skor fonksiyonu değerinde diğer modellere göre daha iyi sonuçlar vermiştir.

Çizelge 3.12 : FD004 veri kümesinde model katmanlarının sonuçlara etkisi.

Model İsimleri	KOKH	Skor Değeri
CSARN1	26,82	4306,49
CSARN2	28,16	4363,26
CSARN3	29,54	5159,06
CSARN4	26,59	4246,91
CSARN5	27,32	4824,32
CSARN6	27,43	4173,06
CSARN7	27,21	3973,54
CSARN	26,39	3800,15

3.6 Sonuçların Karşılaştırılması

Yapılan tez çalışmasının bu bölümünde C-MAPSS veri kümesinde önermiş olduğumuz derin öğrenme modeli ile literatürde önerilen yapıların sonuçları karşılaştırılmıştır. Literatürde C-MAPSS veri kümesi üzerinde birçok çalışmalar

yapılmış ve farklı senaryolar üzerinde çalışılmıştır. KFÖ kestiriminde test veri kümesinde bulunan her bir motor için son sensör verisinden sonra değerlerin üretilmesi ve sonuçların elde edilmesi beklenmiştir. Literatürdeki çalışmalarda özellikle test veri kümesindeki tüm motorların dahil edildiği veriler ve sonuçları alınmıştır. Bazı çalışmalarda kayan zaman penceresi kullanılırken bazıları kullanmamıştır. Önerilen model ile elde edilen KOKH değerleri ve literatürdeki çalışmalarla karşılaştırması Çizelge 3.17’de verilmiştir. Bu çalışmalar içerisinde önerilen modellerin her bir alt veri kümesi içinde çok iyi sonuçları verdiği söylenemez. Ancak modellerin özellikle belirli alt veri kümeleri üzerine yoğunlaşarak o veri kümesinde iyi sonuçlar aldığı ve diğer alt veri kümelerinde yeterli sonuçları alamadığını görebilmekteyiz.

Çizelge 3.13 : Önerilen model ile var olan yöntemlerin sonuçlarının KOKH metriği ile karşılaştırılması.

Yöntemler	FD001	FD002	FD003	FD004
MODBNE[29]	15,04	25,05	12,51	28,66
D-LSTM[38]	16,14	24,49	16,18	28,17
HDNN[45]	13,017	15,24	12,22	18,156
CNNTW[99]	12,18	19,58	15,67	22,12
CapsNet[48]	12,58	16,3	11,71	18,96
DAG[49]	11,96	20,34	12,46	22,43
NPBLSTM[100]	12,321	15,038	11,364	17,752
AT2S[52]	12,63	14,65	11,44	16,66
CNN-BiLSTM[101]	12,13	16,01	11,96	18,01
CNN+ATT[56]	11,48	17,25	12,31	20,58
LSTM-MLSA[55]	11,567	14,019	12,134	17,207
Bi-LSTMTwo-Stream[102]	11,96	14,48	13,41	15,11
BiGRU-TSAM[103]	12,56	18,94	12,45	20,47
LSTM+A[51]	13,95	17,65	12,72	20,21
LSTM+FFNN[51]	13,64	17,76	12,49	21,3
DA-basedCNN[104]	12,25	17,08	13,39	15,65
BiGRU-AS[105]	13,68	20,81	15,53	27,31
HMCB[106]	11,22	14,97	11,34	17,93
ResCNN[35]	12,16	20,85	12,01	24,97
MS-DCNN[107]	11,44	19,35	11,67	22,22
CSARN(KÖDAA)	11,017	23,14	12,63	26,39

Çizelge 3.17 incelendiğinde FD001 alt veri kümesi için KOKH değerinde 11.017 ile en iyi sonucu önermiş olduğumuz model ile elde edilmiştir. FD002 alt veri kümesinde ise karşılaştırmalı sonuçlara baktığımızda LSTM-MLSA modeli 14.48’lik KOKH sonucu ile incelenen literatürdeki en iyi sonuçları elde edilmiştir. FD003 veri kümesi Xue ve ark. sunmuş oldukları paralel bir ağ yapısına dayanan HMCB modeli ile KOKH değerinde 11.34 ile en iyi sonuçları elde etmişlerdir. Jin ve ark. önermiş

oldukları Bi-LSTM Two-Stream modeli ve 15.11’lik KOKH değeri ile FD004 alt veri kümesinde en iyi sonuçları sunmuşlardır [91]. En iyi sonuçlar incelendiğinde karmaşık çalışma koşullarına sahip veri kümelerinde UKHA temelli bir modelin diğer çalışmalar göre daha başarılı olduğu görülmektedir. Ayrıca Jin ve ark. bu çalışmalarında modelin girişine ayrı bir paralel koldan el yordamıyla çıkarılmış öznelikleri de vermişler ve elde edilen zaman uzayındaki öznelikleri regresyon katmanı öncesi birleştirip TBK ile kestirim yapmışlardır [91]. Çizelgede literatürdeki çalışmaların alt veri kümelerinde KOKH değerlerinin en iyi olanları vurgulu şekilde verilmiştir.

Çizelge 3.14 : Önerilen model ile var olan yöntemlerin sonuçlarının Skor metriği ile karşılaştırılması.

Yöntemler	FD001	FD002	FD003	FD004
MODBNE[29]	334,23	5585,34	421,91	6557,62
D-LSTM[38]	338	4450	852	5550
HDNN[45]	245	1282,42	287,72	1527,42
CNNTW[99]	224,16	2494,35	1279,85	4523,32
CapsNet[48]	276,34	1229,72	283,81	2625,64
DAG[49]	229	2730	535	3370
NPBLSTM[100]	238,34	1056,629	226,482	1357,2
AT2S[52]	243	876	263	1074
CNN-BiLSTM[101]	174	1230	242	1513
CNN+ATT[56]	198	1144	251	2072
LSTM-MLSA[55]	252,86	899,18	370,39	1558,48
Bi-LSTMTwo-Stream[102]	206,33	726,82	223,36	892,39
BiGRU-TSAM[103]	213,35	2264,13	232,86	36010,34
LSTM+A[51]	300	1638	267	2904
LSTM+FFNN[51]	320	2102	223	3100
DA-basedCNN[104]	198	1575	290	1741
BiGRU-AS[105]	284	2454	428	4708
HMCB[106]	179,43	1062,35	189,62	1428,4
ResCNN[35]	212,48	2087,77	180,76	3400
MS-DCNN[107]	196,22	3747	241,89	4844
CSARN(KÖDAA)	157,19	2490,09	218,6	3800,15

C-MAPSS veri kümesinde literatürde yapılan çalışmalar ve bu tezde önerilmiş olan modelin skor metriği üzerinden karşılaştırması Çizelge 3.18’de verilmiştir. Çizelgede alt veri kümelerinde elde edilen en iyi sonuçlar vurgulanmıştır. KOKH değeri ile karşılaştırıldığında önerilen model ile FD001 alt veri kümesinde elde edilen skor değeri de en iyisi olduğu görülmektedir. Ancak diğer alt veri kümelerinde skor değerinde farklı çalışmalarda daha iyi sonuçlar alındığı görülmüştür. Tek bir hata ve altı farklı çalışma koşulunda oluşturulmuş FD002 veri kümesinde diziden diziye


dikkat yapısına sahip ve Ragab ve ark. önermiş olduđu model en iyi sonucu vermiştir [52]. FD003 veri kümesinde ise çalışmamızda da yer alan ResNet katmanlarından oluşmuş Wen ve ark. önermiş oldukları ResCNN modeli en düşük skor değerini vermiştir [35]. Uçak motoru veri kümesinin en karmaşık yapısına sahip FD004 veri kümesinde ise Ragab ve ark. önermiş oldukları model ile en düşük skor değerini elde etmişlerdir. Elde edilen sonuçlar göstermektedir ki literatürdeki modeller tüm veri kümeleri için iyi çalışmamaktadır. Farklı çalışma koşulları ve farklı arıza durumları için modellerin özelliklerine göre farklı veri kümeleri için daha iyi değerler elde edilebilmektedir.



4. FEMTO RULMAN VERİ SETİNDE KALAN FAYDALI ÖMÜR TAHMİNİ VE KESTİRİMCİ BAKIM UYGULAMASI

4.1 Veri Kümesi Tanıtılması

Rulman veri kümesi PHM2012 konferansında yapılan veri yarışması için laboratuvar ortamında hazırlanmış bir veri kümesidir. Rulmanlar Franche-Comté Electronics, Mechanics, Thermal Processing, Optics - Science and Technology (FEMTO-ST) enstitüsünün Automatic Control and Micro-Mechatronic Systems (A2S) bölümünün hazırlanmış olduğu PRONOSTIA platformunda test edilmiştir. PRONOSTIA platformu Şekil 4.1’de gösterilmiştir. Bu deney düzeneği dönmeyi oluşturan kısım, bozulmayı oluşturan kısım ve ölçüm kısmı olmak üzere üç ana parçadan oluşmaktadır.



Şekil 4.1 : FEMTO veri kümesinde kullanılan deney düzeneği [15].

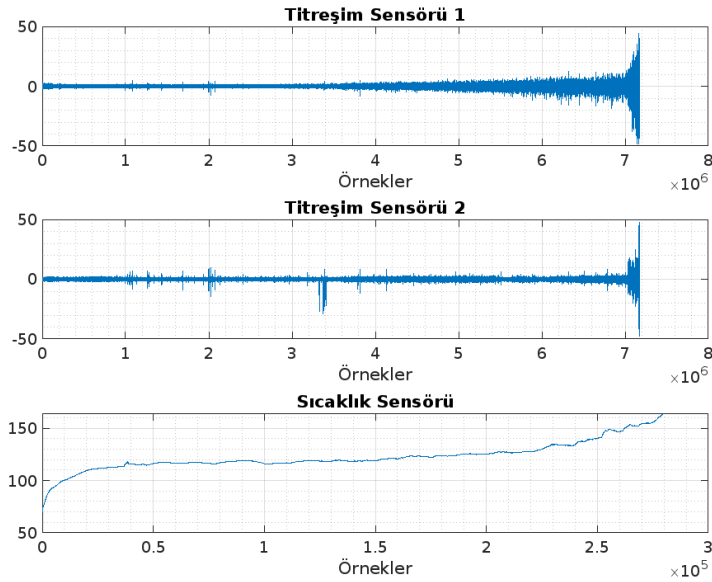
PRONOSTIA deney düzeneğinde bulunan dönen kısım bir asenkron motor ve iki milden oluşan bir dişli kutusundan oluşmaktadır. Bu şaftlardan biri motora yakinen diğer şaft ise artırılmış kodlayıcının yanına yerleştirilmiştir [15]. Düzenekte kullanılan asenkron motor 250 W’lık bir güce sahiptir. Dönme hareketi dişli kutusu yardımıyla 2830 rpm nominal hıza kadar ulaşabilmektedir.

Deney düzeneğinin radyal güç üreten kısım ise bir dikey ekseni ve bunun manivela kolunu, bir pnömotik krikoyu, bir kuvvet sensörünü ile test yatağının bir sıkıştırma halkasını, bir destek test yatağı milini, iki yastık bloğunu ve bunların büyük boyutlu yataklarını içeren bir yapıdan oluşmaktadır [15]. Test rulmanlarına uygulanan radyal

kuvvet dinamik yük yardımıyla 4000 N'a ayarlanarak rulmanların ömrünü azaltmaktadır.

Düzenekte ölçümü yapılan rulmanların çalışma koşulları rulman yatağına uygulanan radyal kuvvet, milin dönüş hızı ve uygulanan torkun anlık ölçümleri ile belirlenmektedir. Rulmanların bozulmalarını takip etmek için titreşim ve sıcaklık verileri kullanılmıştır. Bu verilerden titreşimler ise Şekil 4.1'de gösterildiği gibi birbirine 90° açı yapan iki adet ivmeölçerden alınmaktadır. Sıcaklık sensörü de rulmana en yakın konumda konumlandırılmıştır. Çalışma koşulları ifade eden veriler 100 Hertz (Hz) ile toplanmaktadır. Titreşim verileri ise sensörlerden 25.6 kiloHertz(kHz) örneklem frekansı ile alınmakta, sıcaklık verileri ise 10 Hz örnekleme frekansı ile toplanmaktadır [15].

Bu veri kümesinde rulmanlar farklı hızlarda ve farklı yüklerde test edilmiştir. Ayrıca farklı arıza modları oluşturulmuş veya birden fazla arızayla daha gerçekçi veriler elde edilmiştir [108]. Şekilde görülmekte olan ivmeölçer ve sıcaklık sensörleri ile rulmandan veriler toplanmaktadır. Yarışma için hazırlanan bu platform ile kısa bir süre içerisinde rulmanların arızalana kadarki bozulma verilerini birkaç saatlik dilimler ile toplanabilmesi sağlamıştır [15].




Şekil 4.2 : FEMTO veri kümesindeki 1_1'nolu rulmanın sensör grafikleri.


Çizelge 4.1 : Rulman veri kümesinin detayları.

Veri kümesi	Çalışma Koşulları		
	Birinci	İkinci	Üçüncü
Eğitim veri kümesi	Rulman1_1	Rulman2_1	Rulman3_1
	Rulman2_2	Rulman2_2	Rulman2_2
Test veri kümesi	Rulman1_3	Rulman2_3	Rulman3_3
	Rulman1_4	Rulman2_4	
	Rulman1_5	Rulman2_5	
	Rulman1_6	Rulman2_6	
	Rulman1_7	Rulman2_7	

Veri kümesi oluşturulurken üç farklı çalışma koşulları ile rulmanlar test edilmiştir. Rulmanların çalıştırma koşulları sırasıyla 1800 rpm (rotate per minute) ve 4000 Newton(N), 1650 rpm ve 4200 N, 1500 rpm ve 5000 N olarak ayarlanmıştır. Yarışma için oluşturulan veri kümesinde toplamda 17 adet rulman test edilmiştir. Veri kümesi de Çizelge 4.1’de verildiği gibi başlangıçta eğitim ve test rulmanları olarak ayrılmış ve belirtilmiştir. Bu veri kümesinde çalışma koşullarına göre üç grupta değerlendirme yapılmıştır. Rulmanların isimlendirilmesi de bu çalışma koşullarına göre olmaktadır. 1800 rpm ve 4000 N yüke sahip birinci çalışma koşulunda 7 adet rulman test edilmiştir. 1650 rpm ve 4200 N yüke sahip ikinci çalışma koşulunda ise 7 adet rulman çalıştırılmıştır. 1500 rpm ve 5000 N yüke sahip son çalışma koşulunda ise 3 adet rulman test edilmiştir. Her çalışma koşulunun ilk iki rulman verisi eğitim veri kümesi olarak ayrılmıştır.




Şekil 4.3 : FEMTO eğitim veri kümesindeki tüm rulmanların ilk titreşim sensör grafikleri.



Şekil 4.4 : FEMTO-ST veri kümesinde titreşim verilerinin toplanma çizelgesi.

PRONOSTIA deney düzeneğinde toplanan veriler farklı örnekleme frekansına göre toplanmıştır. İçermiş oldukları bilgiye göre titreşim verileri daha yüksek örnekleme sahiptir. Ancak verilerin veri kümesine alınırken farklı bir işlemden geçirilmiştir. Sıcaklık verileri 10 Hz örnekleme frekansı ile toplanırken tüm veriler veri kümesine kaydedilmektedir. Ancak titreşim verileri yüksek örnekleme frekansına sahip olması ile rulmanların çalışma sürelerini uzun olması sonucunda büyük bir veri miktarını oluşturmaktadır. Veri yarışmasında veri kümesi oluşturulurken titreşim verileri 10 saniyelik bir periyodun ilk 100 milisaniyesi boyunca veri kümesine kaydedilmiştir. Hazırlanan verilerin zaman çizelgesi Şekil 4.4'te verilmiştir. Yapılan bu işlem ile titreşim verilerinin boyutu 100'de 1 oranında küçültülmüştür. Bu veriler üzerinden KFÖ kestirimi yapılması beklenmektedir.

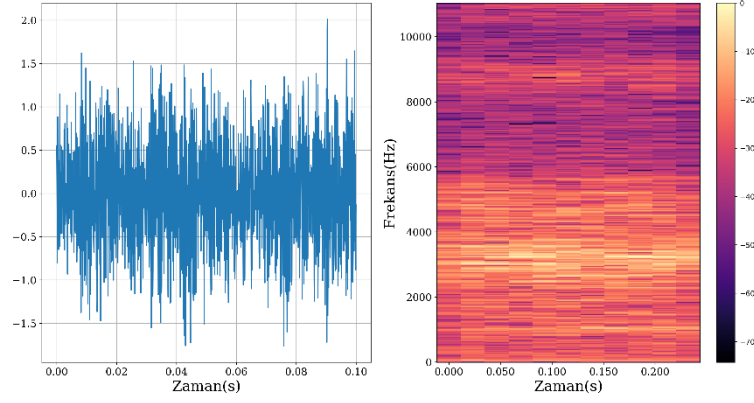
Rulmanlardan üç farklı sensör ile veriler toplanmaktadır. Birinci çalışma koşulunda bulunan Rulman1_1 ait sensör verileri Şekil 4.2'de verilmektedir. Eğitim veri kümesinde bulunan tüm rulmanlar bozulma anına kadarki verileri verilmektedir. Test veri kümesinde bulunan rulmanların ise belli bir süreye kadar verileri bulunmakta ve belirlenen hedef olarak bozulma anına kadar olan KFÖ değerinin kestirilmesi beklenmektedir. Eğitim veri kümesinde bulunan altı adet rulmanın birinci titreşim sensörüne ait grafikleri Şekil 4.3'te verilmektedir. Test veri kümesinde bulunan rulmanların kestirim için olan kısımları ile bozulma anına kadar toplanan titreşim verileri ise Şekil 4.5'te verilmektedir. Bu grafiklerde test için ayrılan titreşim verileri kestirim modeline verilerek çıkışında rulmana ait KFÖ kestirimi yapılmaktadır.



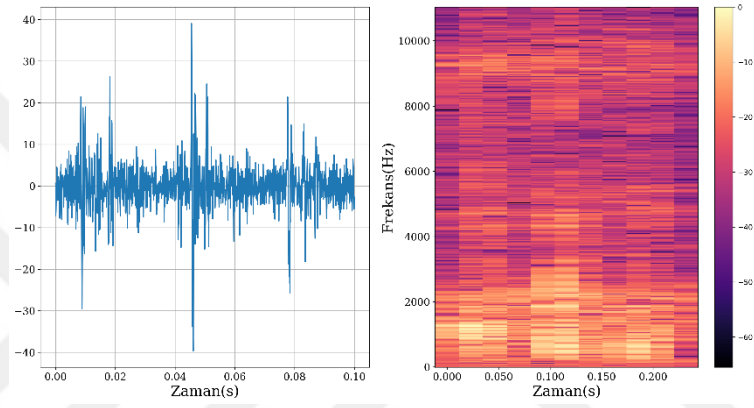
Şekil 4.5 : FEMTO test veri kümesindeki tüm rulmanların ilk titreşim sensör grafikleri.

4.2 Önışleme

Bu tez kapsamında FEMTO-ST rulman veri kümesi üzerinde KFÖ kestirimi yapılacaktır. Veri kümesinde bulunan veriler detaylıca incelenecek ve önerilen model için veri kümesi hazır hale getirilecektir. Veri kümesinde bulunan rulmanların durumunu izleyen iki adet titreşim sensörü ve bir adet sıcaklık sensörü bulunmaktadır. Titreşim verileri 25.6 kHz örnekleme frekansı ile sıcaklık verileri ise 10 Hz örnekleme frekansı ile toplanmıştır. Her bir rulmandaki sensör verileri ayrı ayrı incelenmiştir.




Şekil 4.6 : Rulman1_1'e ait ilk titreşim sensörünün ilk 100 ms'lik kısmının zaman ve frekans uzayındaki temsili.




Şekil 4.7 : Rulman1_1'e ait ilk titreşim sensörünün son 100 ms'lik kısmının zaman ve frekans uzayındaki temsili.

Rulman veri kümesinde her bir rulmana ait iki adet titreşim verisi bulunmaktadır. Bu veriler ses verileri gibi zaman uzayında genlik değerlerine sahip tek boyutlu verilerdir. Rulmanlara ait titreşim verileri 10 saniyelik periyotlarla alınmış ve bu periyotların ilk 100 ms'lik kısmının kaydedilmesinden oluşmaktadır. Böylelikle tek bir kısımda 2560 örnek tek bir titreşim sensöründen alınmaktadır. Bu veriler zamanla değişmesi ve yüksek örnekleme frekansına sahip olması ile hem düşük hem de yüksek frekanslarda değerlere sahiptir ve frekans spektrumu olarak temsil edilebilmektedirler. Bir titreşim verisinin veya zamanla değişen bir sinyalin Hızlı Fourier Dönüşümü ile frekans uzayında incelemesi yapılabilir. Şekil 4.6'da Rulman1_1 ait ilk 100 ms'lik kısmı ile Şekil 4.7'de bozulmadan önceki son 100 ms'lik kısmın hem zaman uzayında hem de frekans uzayındaki logaritmik temsilleri verilmiştir. Ayrıca Şekil 4.8'de Rulman1_2'e ait tüm çalışma süresi boyunca ki zaman uzayında ve frekans uzayındaki gösterimleri verilmiştir. Grafikten de görüldüğü üzere zaman uzayında bozulmaya yakın zamanda meydana gelen titreşimdeki değişimler frekans uzayında da frekans değişiminde

gözükmemektedir. Ancak belirgin değişimin olmadığı diğer zamanlarda iki uzayda da bozulmayı yakalamak zor olmaktadır.



(a)



(b)

Şekil 4.8 : Rulman1_2'nin zaman ve frekans uzayındaki temsilleri.

Titreşim verilerinin durağan olmayan yapısı sebebiyle zamanda küçük parçalara ayırıp analiz yapılması gerekmektedir. Böylelikle verilerin bu kısa parçalar süresince kararlı davranış sergilediği varsayılarak analizi yapılacaktır. Bu şekilde yapılan işleme Kısa Dönem Analizi denir [109]. Ayrıca titreşim verileri kısa süreli parçalara ayrıldıktan sonra bir pencereleme işlemi ile çarpılmaktadır. Bu alınan kısa parçalar uygulamadan uygulamaya geçmiş olsa da 20 ile 50 ms aralığında olmaktadır. Bununla birlikte titreşim verisinden parça alındıktan sonra bir sonraki parça için örtüşme miktarına bağlı olarak kaydırma işlemi yapılmakta ve örtüşme miktarı 10 ile 25 ms aralığında olabilmektedir. Alınan her bir parça literatürdeki farklı pencereleme fonksiyonları ile çarpılmaktadır. Ardından her bir pencerelenmiş sinyalin Ayırık Fourier Dönüşümünün uygulamadaki hali olan Hızlı Fourier Dönüşümü (HFD) alınıp

genlik değeri elde edilerek spektrogramı oluşturulmaktadır. Bu tez çalışmasında ‘‘Hann’’ pencereleme işlemi kullanılmıştır. Hann pencereleme işleminin denklemi Denklem 4.1’de verilmiştir. HFD çerçevenmiş bir sinyaldeki genlik spektrumunu ifade eden denklemi Denklem 4.2’de verilmiştir [109].

$$w(n) = 0.5 - 0.5 \cos\left(\frac{2\pi n}{M-1}\right), \quad 0 \leq n \leq M-1 \quad (4.1)$$


$$S_{FFT}(k) = \left| \sum_{n=0}^{N-1} s(n) e^{-\frac{j2\pi kn}{N}} \right|^2, \quad 0 \leq k \leq N-1 \quad (4.2)$$

Denklemdaki k değeri ayrık frekans indisini, s(n) fonksiyonu ise pencerelenmiş çerçeveyi göstermektedir. s(n) değeri belirtilen aralık dışında 0 değerini almaktadır. Bu tez çalışması boyunca rulman titreşim verilerinde özellikle ses sinyallerinin işlenmesinde başarılı sonuçlar veren Mel spektrogram yapısı kullanılmıştır. Mel spektrogramı elde edilirken öncelikle titreşim verileri parçalara ayrılmaktadır. Ardından Hann penceresi ile çarpılarak pencereleme işleminden geçirilmektedir. Elde edilen yeni sinyal zaman boyutundan frekans uzayına geçirilirken HFD’ye tabi olur. Elde edilen genlik spektrumu ile titreşim verisinden alınan 100 ms’lik bir parçanın spektrogramı elde edilir. Bu parçanın pencerelenmiş her bir kısmı birbirine ardışık olarak yerleşmiş band-geçiren üçgen süzgeç takımından geçirilmektedir. Bu süzgeçler mel ölçeğinde bulunan standart yapıdaki süzgeçlerdir. Buradaki süzgeçlerin merkez frekansları Denklemde 4.3’te verilmiştir.


$$f_{MEL} = 1000 \frac{\log\left(1 + \frac{f_{Hz}}{1000}\right)}{\log 2} \quad (4.3)$$

Böylelikle frekans uzayından mel süzgeçleri ile Mel frekans uzayına geçilmektedir. Ardından kullanılacak olan frekans uzayı daha iyi ifade edilebilmesi için logaritması alınarak logaritmik Mel spektrogramı elde edilmektedir. Bu tez çalışmasında titreşim verilerinden 100 ms’lik parçalar alınarak veriler işlenmeye başlanmaktadır. Ardından HFD hesaplanması için gerekli olan pencereleme işleminde bu titreşim sinyalleri 40 ms’lik parçalara ayrılmıştır. Bu parçalar ise 10 ms’lik kaydırma işlemi ile tüm sinyal üzerinde gezdirilmiştir. İlk alınan 40 ms’lik sinyal Hann pencereleme işleminden geçirilmiştir. Bu süreçte pencereleme işlemi tüm 100 ms’lik sinyalde gezdirilirken sıfır

doldurma işlemi uygulanmıştır. Ardından sinyal 128 adet mel süzgecinden geçirilmiştir. Elde edilen verilerin logaritması alınarak Mel Spektrogramı elde edilerek veri kümesi ilk aşama için kullanıma hazır hale getirilmiş olur. Şekil 4.9'de Rulman1_1 titreşim verisinin ilk 100ms'lik kısmının zaman uzayındaki durumu ile logaritmik mel spektrogramı gösterilmiştir. Şekil 4.10'da Rulman1_1 titreşim verisinin son 100 ms'lik kısmının zaman uzayındaki durumu ile logaritmik mel spektrogramı gösterilmiştir.



Şekil 4.9 : Rulman1_1'e ait ilk titreşim sensörünün ilk 100 ms'lik kısmının zaman ve mel frekans uzayındaki temsili.




Şekil 4.10 : Rulman1_1'e ait ilk titreşim sensörünün son 100 ms'lik kısmının zaman ve mel frekans uzayındaki temsili.

Yapılan kestirimci bakım çalışmalarında bir sistemin veya parçasının hedeflenen bozulma modelleri farklılık göstermektedir. Bir sistemin her bir çalışma anından sonra ömründen bir azaldığı kabul edilmektedir. Bu azalma incelenen birime göre bir çevrim süresi, bir saniye, saat, gün olabileceği gibi yapılan işi tanımlayan yeni bir yapıda olabilmektedir. Literatürde rulman verileri için kullanılan bozulma modeli doğrusal bozulma modeli olarak geçmektedir. Bu modele göre her rulman çalışmasında ömründen saniye bazında bir azalma söz konusu olmaktadır. FEMTO-ST veri kümesi

üzerinde yapılan çalışma da alınan örnekler 10 saniyelik periyotlar ile alındığı için her bir hesaplama sonucunda ömründen 10 saniyelik bir zaman düşmektedir. Şekil 4.11’de rulman ömrünü kestirmek için kullanılacak bozulma modeli gösterilmiştir. C-MAPSS veri kümesinde çalışılan motorların ömürleri arasında büyük farklar olmaması sebebiyle parçalı doğrusal bir model sunulurken Şekil 1.2’de gösterildiği gibi rulmanlarda çok farklı zaman dilimlerinde ömürlere sahip olması sebebiyle doğrusal bir model tercih edilmiştir. FEMTO-ST veri kümesinde kullanılan rulmanların tüm çalışma ömürleri ile test veri kümesinde bulunan rulmanların ömürleri ile kestirim anları Çizelge 4.2’de gösterilmiştir. Büyük farklılıklar sebebiyle ve literatürde adil bir karşılaştırma için doğrusal bir bozulma modeli kullanılmıştır.


Çizelge 4.2 : FEMTO-ST rulman veri kümesindeki tüm rulmanların çalışma ömürleri.

Rulmanlar	Verinin olduğu süre(s)	Çalışma ömrü(s)
Rulman1_1	28030	28030
Rulman1_2	8710	8710
Rulman2_1	9110	9110
Rulman2_2	7970	7970
Rulman3_1	5150	5150
Rulman3_2	16370	16370
Rulman1_3	18010	23740
Rulman1_4	11380	14270
Rulman1_5	23010	24620
Rulman1_6	23010	24470
Rulman1_7	15010	22580
Rulman2_3	12010	19540
Rulman2_4	6110	7500
Rulman2_5	22010	23100
Rulman2_6	5710	7000
Rulman2_7	1710	2290
Rulman3_3	3510	4330




Şekil 4.11 : Rulman3_1 ve Rulman3_2'e ait bozulma modelleri.

FEMTO-ST verisi setinde rulmanlardan üç adet sensör yardımıyla veriler toplanmaktadır. Ancak bu çalışma boyunca verinin boyutunu azaltmak için sadece ilk titreşim verisi kullanılmıştır. Rulmanlara ait ilk titreşim sensöründen alınan veriler ilk olarak ön işleme tabi tutulmuştur. Veri kümesinin hazırlanmış halini yani 10 saniyede 100 milisaniyelik örnekleri zaman uzayından mel ölçekli frekans uzayına taşınmıştır. Böylelikle her bir parça için bir adet spektrogram elde edilmiştir. Uçak motoru veri kümesinde olduğu gibi geçmişe dair verilerin KFÖ kestirimi için bilgi taşıdığı varsayımı ile 100 ms'den elde edilen spektrogramlar kayan pencere işlemine tabi tutulmuştur. Bu çalışma kapsamında belirlenen pencere boyutu 10 adet örnek olup her bir örnekte 10 saniyelik periyotlardan oluşmaktadır. Her bir parçanın spektrogramı da yan yana koyularak yeni bir matris elde edilmiştir. Kayan zaman pencere çalışması Şekil 4.12'de gösterilmektedir. Şekil 4.12a'da 10 tane ard arda gelmiş mel spektrogramlar gösterilmiştir. Grafik 4.12b'de ise bu spektrogramların yan yana bir araya getirilip eğitim için oluşturulan yeni örnekler gösterilmiştir.



(a)



(b)

Şekil 4.12 : Kayan zaman penceresi tekniğinin mel spektrogram üzerinde uygulanması.

Titreşim verileri zaman uzayından mel frekans uzayına alındıktan sonra kayan zaman pencere tekniği uygulanmıştır. Elde edilen yeni veri kümesinde her bir örnek matrislerden oluşmaktadır. Bu veri kümesi içerisinde bazı değerlerin çok küçük olması ve bazı değerlerin çok büyük olması sebebiyle önerilen derin öğrenme modelinde etkisi tam olarak görülememektedir. Bu sebeple veri kümesine normalizasyon işlemi yapılmıştır. Eğitim veri kümesi olarak alınan üç farklı çalışma koşulunun ilk iki rulman verilerinden elde edilen yeni spektrogram verisinden hiper parametreler alınmıştır. Normalizasyon işlemi ile değerler -1 ile 1 arasına çekilmiştir. Normalizasyon denklemi Denklem 4.4'te gösterilmiştir.

$$\hat{X} = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (4.4)$$

Burada $\min(X)$ ve $\max(X)$ deęerleri sırasıyla eęitim veri kümesinde bulunan minimum deęer ile maksimum deęeri ifade etmektedir. Böylelikle veri kümesi normalize edilmiř olur.


Veri kümesi PHM2012 konferansı veri yarışması için özel olarak hazırlanmıřtır. Farklı kestirimci bakım problemleri için bu veri yarışmalarında farklı deęerlendirme metrikleri önerilmektedir. Bu yarışma kapsamında ise yapılan çalışmaların karşılařtırmasını yapabilmek için hem bir çalışma protokolü hem de yeni bir deęerlendirme metrięi sunulmuřtur. Bu deęerlendirme metrięi Denklem 4.5-4.7'de verilmiřtir.

$$\%E_{r_i} = \frac{KF\ddot{O}_i - \widehat{KF\ddot{O}}_i}{KF\ddot{O}_i} \quad (4.5)$$

$$A_i = \begin{cases} e^{-\ln(0.5)\left(\frac{E_{r_i}}{5}\right)}, & \text{eęer } E_{r_i} \leq 0 \\ e^{+\ln(0.5)\left(\frac{E_{r_i}}{20}\right)}, & \text{eęer } E_{r_i} > 0 \end{cases} \quad (4.6)$$

$$Skor = \frac{1}{11} \sum_{i=1}^{11} A_i \quad (4.7)$$

Yukarıdaki denklem setinde i ile bildirilen deęerler test veri kümesinde bulunan rulmanları ifade etmektedir. İlk denklemde gösterilen $KF\ddot{O}_i$ ifadesi gerçek $KF\ddot{O}$ deęerini gösterirken $\widehat{KF\ddot{O}}_i$ ifadesi de i . rulmana ait yapılan kestirimi ifade etmektedir. Her rulmanın ömür kestirimi için asimetrik bir puan ataması A_i ile yapılmaktadır. Őekil 4.13'te deęerlendirme metrięinin aldıęı deęerlere göre grafięi gösterilmiřtir. Grafikten de görüleceęi üzere yüzdelik hatanın pozitif olduęu yerlerde daha yüksek alınmakta ve birebir kestirim yapıldıęında ise o rulman için 1 deęerini vermektedir. Böylelikle rulmanların gerçek bozulma zamanından daha geç bir kestirim yapılıncaya oluřacak büyük arızanın önüne geçilmek istenmektedir. Son denklemde ifade edilen 11 deęeri test veri kümesinde kalan 11 adet rulmanı ifade etmektedir.



Şekil 4.13 : Yarışma için oluşturulmuş değerlendirme metriği.

4.3 Önerilen Model

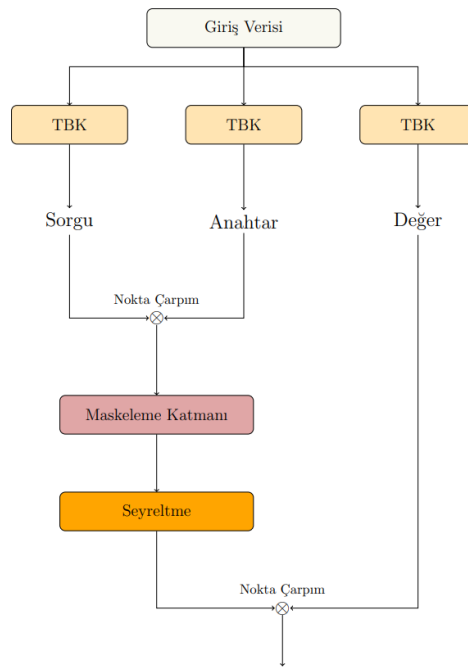
Bu tez kapsamında FEMTO-ST rulman veri kümesi üzerinde Kalan Faydalı Ömür kestirimi üzerine çalışma yapılmıştır. Bu çalışma kapsamında rulmanlardan alınan titreşim verileri önişlemeden geçirildikten sonra özellikle ses sinyalleri gibi yüksek örnekleme frekansına sahip veriler içinde kullanılmış dönüştürücü katmanına sahip bir derin öğrenme modeli sunulmuştur. Veri kümesi 17 rulmandan oluşmakta ve bu rulmanlar Çizelge 4.1'de gösterildiği gibi eğitim ve test veri kümesine ayrılmıştır.

Veri kümesinin eğitim ve test verisi olarak ayrılması veri yarışmasında önceden belirlenmiş bir senaryo üzerine yapılmıştır. Ardından rulmanların durumunu izleyen 2 titreşim sensörü ve 1 sıcaklık sensör verileri elde edilmiştir. Bu verilerden her rulman için süreklilik ifade eden ilk titreşim verisi kestirim yapmak için seçilmiştir. Bu titreşim verileri deney düzeneğinden alınan veri toplama senaryosuna göre yani 10 saniyelik periyotlarda 100 ms'lik kayıtlara göre önişlem yapılabilmesi için ayrılmıştır. Yüksek örnekleme frekansına sahip bu veriler zaman uzayından HFD ile frekans uzayına alınmıştır. Ardından frekans skalası logaritmik olarak ölçeklenerek daha iyi temsilini yapabilmek için 128 adet mel süzgecinden geçirilip mel frekansına uygun hale getirilmiştir. Elde edilen sinyaller logaritması alınarak logaritmik mel spektogramı elde edilir. Zaman uzayında bir titreşim verisi mel frekans uzayında temsil edilmiş olmaktadır. Her bir 10 saniyelik kısımda bir adet matris elde edilmiş olur. Tek bir titreşim verisinin KFÖ kestirimi için yeterli bilgi içermemesi ve kestirim problemlerinde geçmiş verilerdeki bilgilerin KFÖ kestirimine etkisi sebebiyle kayan zaman pencere tekniği uygulanmıştır. Kayan zaman penceresi yönteminde pencere boyutu 10 olarak belirlenmiş ve elde edilen matrislere zaman boyutunda ekleme

yapılarak yeni veri kümesi elde edilmiştir. Kayan pencere yönteminde 10 saniyelik parçalardan birer kayma işlemi uygulanmıştır. Elde edilen son veri kümesi işlenmeden önce normalize edilmiş ve modelin girişi için hazırlanmıştır. Bu çalışmada hedef değer olan bozulma modelin doğrusal bozulma modeli kullanılmış ve rulmanların her bir adımı için KFÖ değeri ataması yapılmıştır. Böylelikle veri kümesi kestirim için hazır hale getirilmiştir.

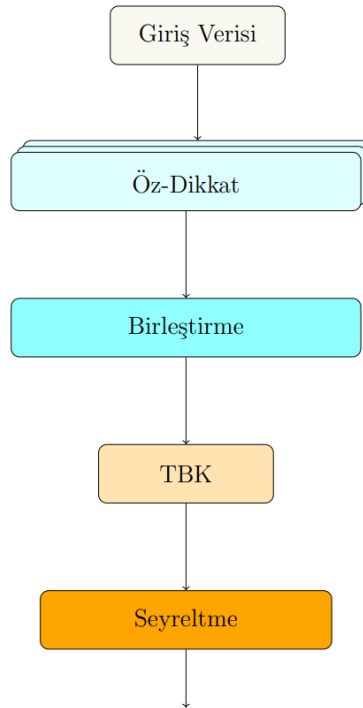
Kestirim probleminde ses sinyallerinde olduğu gibi yüksek örnekleme frekansına sahip rulman titreşim verileri kullanılmaktadır. Ses sinyalleri üzerinde konuşma tanıma uygulamasında Dönüştürücü yapıları yüksek başarımlar elde etmişlerdir [110]. Bu çalışma kapsamında kullanılan derin öğrenme modeli temel alınmış ve rulman veri kümesine uygulanmıştır. Model yapısı içerisinde Dönüştürücü katmanları kullanılmış ve bu katmanların temelini de Öz-Dikkat yapısı oluşturmaktadır.

Bu çalışma kapsamında önerilen derin öğrenme modelimiz ilk katmanında 1 boyutlu ESA yapısı ile başlamaktadır. Bu katmanlar yardımıyla daha az ağırlık katsayısı yardımıyla giriş matrisinden öznitelikler çıkarılmaktadır. Evrişim işlemlerinden sonra doğrusal olmayan yapının sağlanması için elde edilen değerler "GELU" aktivasyon fonksiyonu ile çarpılmaktadır [30]. Kullanılan iki evrişim katmanı süzgeç sayısı, süzgeç boyutu ve dolgulama özellikleri yönünden aynı şekilde tasarlanmıştır. Böylelikle iki katman ile daha yüksek nitelikli öznitelikler çıkarılması amaçlanmıştır.



Şekil 4.14 : Önerilen öz-dikkat katmanı.

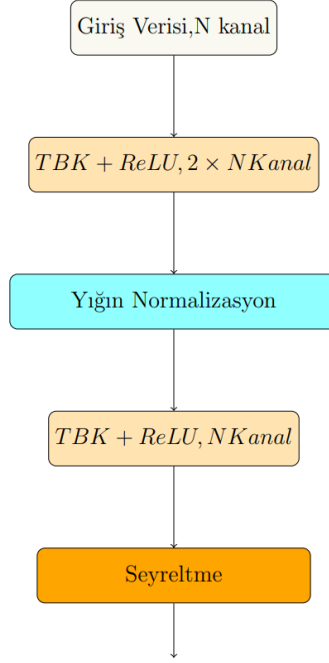
Literatürde farklı uygulamalarda kullanılan Öz-Dikkat katmanının sonuçlara olan etkisi bildirilmektedir. Dönüştürücü katmanının temelini oluşturan Öz-Dikkat katmanının verimliliği, veri kümesinde kullanılan model için üzerinde değişikliğe gidilmiştir. Kullanılan katmanda giriş kaynak tensörü TBK ile sorgu, anahtar ve değer olmak üzere üç tensör yapısına dönüştürülmektedir. Bu tensörler elde edilirken yoğun bir ağırlık katsayısı kullanımı söz konusu olmaktadır. Ardından sorgu tensörü anahtar tensörünün transpozesi alınarak nokta çarpımı yapılmaktadır. Elde edilen harita tensörü maskeleyme katmanından geçirilip “softmax” aktivasyon fonksiyonu ile çarpılmaktadır. Böylelikle tensör üzerinde odaklanmak istenen bölgeler belirlenmeye çalışılmaktadır. Modelin ezberlemesini engellemek için bu katmandan sonra Seyreltme katmanı kullanılır ve ardından değer tensörü ile nokta çarpımı yapılarak Öz-Dikkat katmanının çıkışı elde edilmiş olur. Önerilen Öz-Dikkat katmanı Şekil 4.14’te gösterilmiştir.



Şekil 4.15 : Önerilen çok başlı dikkat katmanı.

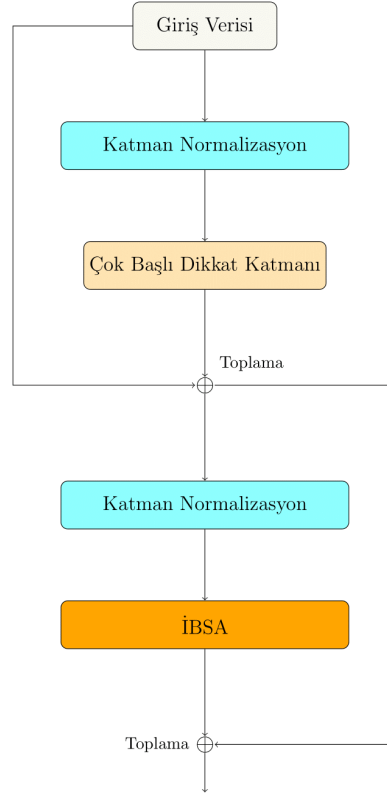
Önerilen model yapısında kullanılan Öz-Dikkat katmanlarının her biri kullanılan ağırlık katsayılarına göre tensör üzerinde odaklanması gereken noktaları göstermektedir. Çok Başlı Dikkat katmanı ile gelen tensör yapısını daha küçük parçalara ayırıp farklı odak noktaları oluşturan dikkat haritası çıkarılması sağlanmaktadır. Çok Başlı Dikkat Katmanı yapısı Şekil 4.15’te gösterilmiştir. Daha

önceki bölümde bahsedilen yapıdan farklı olarak ölçeklenmiş Öz-Dikkat katmanı kullanılmamış ve son TBK katmanından sonra ezberlemeyi önlemek için seyreltme katmanı kullanılmıştır.



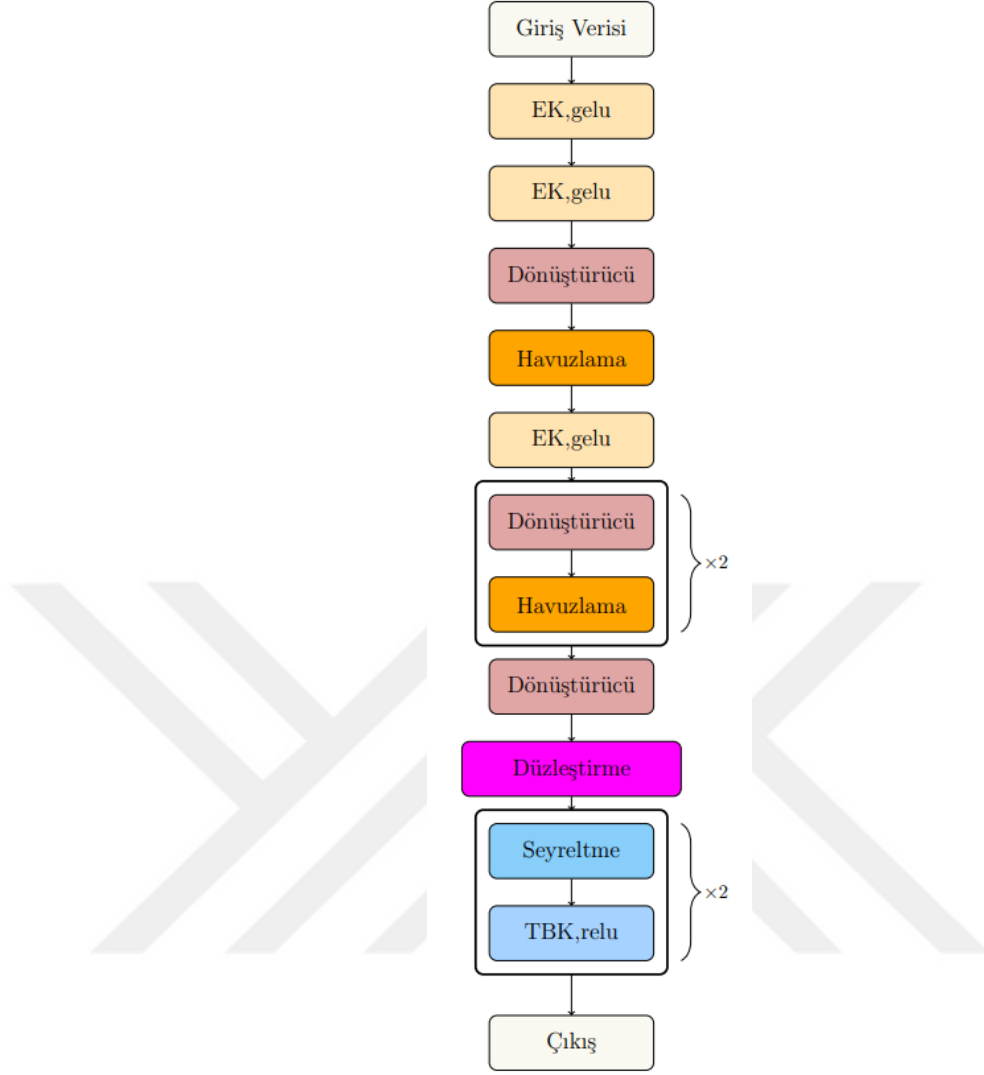
Şekil 4.16 : Önerilen ileri beslemeli sinir ağı.

Bölüm 2’de bahsedilen dönüştürücü yapısında bulunan İleri Beslemeli Sinir Ağı yapısı bu çalışma kapsamında da değişiklik yapılar kullanılmıştır. Önerilen İBSA yapısında giriş tensörü kanal boyutu üzerinden TBK ile 2 katına çıkarılmaktadır. Ardından yığın normalizasyon yapılmakta ve tekrar giriş kanal boyutuna indiren TBK katmanı kullanılmaktadır. Böylelikle öznitelikler daha hedefe yönelik olmakta ve model derinleşmektedir. Katmanın çıkışında ise ezber engellenmek için seyreltme kullanılmaktadır. Önerilen yapı Şekil 4.16’da gösterilmektedir.



Şekil 4.17 : Önerilen dönüştürücü katmanı.

FEMTO-ST rulman veri kümesi için önermiş olduğumuz dönüştürücü yapısının temelleri gösterilmiştir. Bu katmanlar dönüştürücü içerisinde bilgi çıkarımı ve aktarımı için kullanılmıştır. Önerilen dönüştürücü yapısında giriş tensörü öncelikle katman normalizasyonu ile normalize edilmektedir. Ardından önermiş olduğumuz ÇBDK katmanından geçmektedir. Şekil 4.17’de gösterildiği gibi giriş tensörü ile ÇBDK’dan çıkan değerler toplanmakta ve bir sonraki katmana aktarılmaktadır. Böylelikle derin sinir ağında ileri beslemede kısayol kullanılmış olmaktadır. Bununla birlikte çıkış katmanında oluşan hatanın ilk katmanlara doğru etki etmesi sağlanmaktadır. Toplanan değerler tekrar katman normalizasyonundan geçmektedir. Çıkış öncesi İBSA yapısından geçerek çıkışta tekrar kısayol ile toplama işlemine tabi olmaktadır. Böylelikle özellikle doğal dil işleme de sıklıkla kullanılan dönüştürücü yapısı önermiş olduğumuz model için oluşturulmuş olur.



Şekil 4.18 : Rulman titreşim verileri için önerilen derin öğrenme yapısı.

Rulman titreşim verilerinin KFÖ kestirimi için önerilen derin öğrenme modeli dönüştürücü katmanları, evrişim katmanları, havuzlama katmanları ve TBK'ların birleşiminden oluşmaktadır. Önerilen model Şekil 4.18'de gösterilmiştir. Bu yapının Düzleştirme katmanı sonrası KFÖ kestirimi için özneliklerin kullanılmasını içermektedir. Bu katmanlar arasından Seyreltme katmanı kullanılmıştır. Modelin derin olması, çok fazla ağırlık katsayılarına sahip olması sebebiyle ezberlemeye eğilimlidir. Bu seyreltme katmanları ezberlemenin önüne geçmeyi hedeflemektedir. Ayrıca evrişim katmanları ve dönüştürücü katmanları girişinde gelen tensör çıkışlarında da aynı boyutlu ya da kanal boyutu değişerek çıkmaktadır. Model içerisinde kullanılan maksimum havuzlama katmanı ile tensörlerin boyutu indirgenmesi amaçlanmıştır. Böylelikle çıkışa doğru geldikçe boyut düşmekte ve daha az öznelikle kestirim yapılmaktadır. Önerilen derin öğrenme modelinin detayları Çizelge 4.3'te verilmiştir.

Çizelge 4.3 : Önerilen dönüştürücü temelli modelinin detayları.


Katman İsmi	Giriş Boyutu	Çıkış Boyutu	Açıklama
Evrişim1B 1	128x110	128x256	21, 256 süzgeç
Evrişim1B 2	128x256	128x256	21, 256 süzgeç
Dönüştürücü 1	128x256	128x256	16 başlı ÇBDK
Havuzlama1B 1	128x256	64x256	
Evrişim1B 3	64x256	64x256	11, 256 süzgeç
Dönüştürücü 2	64x256	64x256	8 başlı ÇBDK
Havuzlama1B 2	64x256	32x256	
Dönüştürücü 3	32x256	32x256	8 başlı ÇBDK
Havuzlama1B 3	32x256	10x256	
Dönüştürücü 4	10x256	10x256	8 başlı ÇBDK
Düzleştirme Katmanı	10x256	2560	
Seyreltme 1	2560	2560	Seyreltme Oranı=0.3
Tam Bağlı Katman 1	2560	192	
Seyreltme 2	192	192	Seyreltme Oranı=0.3
Tam Bağlı Katman 2	192	96	
Tam Bağlı Katman 3	96	1	

KFÖ kestirimi için önerilen derin öğrenme modeli eğitilmek için Colab ortamında Python programlama dilinde geliştirilmiş ve eğitilmiştir. Model yapısının eğitiminde “adam” optimizasyon algoritması kullanılmıştır. Modelin eğitilmesi için ayrılan eğitim veri kümesi veri yarışmasında belirlenen rulman verileri üzerinden yapılmıştır. Bu eğitim verileri yine yüzde 80’ni eğitimde yüzde 20’si doğrulamada olacak şekilde bölünmüştür. Eğitilen model doğrulama kümesi ile test edilip tekrar ağırlıklarını güncellenmesi sağlanmıştır. Modelin eğitimi yapılırken hedeflenen optimum noktaya daha hızlı yakınsaması için mini-grup yöntemi kullanılmıştır. Belirlen grup büyüklüğü 128 örnekten oluşmaktadır. Modelin ağırlık katsayılarının fazla olması ve derin bir yapıya sahip olması sebebiyle eğitim için 350 devirlik bir süreç belirlenmiştir. Ayrıca model eğitimi sırasında yapının veriyi ezberlemesini engellemek için model eğitimi durdurulması planlanmıştır. Bu sebeple eğitim kayıp fonksiyonu değeri ile doğrulama kayıp fonksiyonu değerinin eğilimi değiştiği noktadan 20 devir sonrasında eğitimin durdurulması sağlanmıştır.


4.4 Deneysel Sonuçların Analizi

Tezin bu bölümünde rulman titreşim veri kümesi için önerilen model ile elde edilen sonuçlar anlatılmıştır. Bu çalışma kapsamında FEMTO-ST veri kümesinde üç farklı çalışma koşulunda rulmanlar test edilmiş ve KFÖ kestirimi yapılması beklenmiştir. Veriler öncelikle zaman boyutundan mel frekans boyutuna alınmıştır. Ardından kayan


zaman penceresi uygulanmış ve veriler son durumda normalize edilmiştir. Kullanılan rulmanların ömürleri başlangıçtaki durumları ve çalışma koşullarına göre değişiklik göstermektedir. Her bir rulman için dönme eylemi başladıktan sonra veriler alınmaya başlanmış ve arıza olana kadar tüm titreşim verileri alınmıştır. Test veri kümesinde bu titreşim verileri bir noktada kesilmiş ve geriye kalan sürenin kestirilmesi beklenmiştir. Birinci çalışma koşulu rulmanlar için 1800 rpm ve 4000 N'luk bir yük ile yapılmıştır. Toplamda bu koşullarda 7 farklı rulman kullanılmış ve bunlardan 2 tanesi eğitim veri kümesinde bulundurulmuştur. Toplamda altı adet rulmanla eğitilen önerilen model sırasıyla test veri kümesindeki rulmanların her bir adımı için test edilmiş ve KFÖ değeri vermesi sağlanmıştır. Şekil 4.19'da birinci çalışma koşulunda test veri kümesinde bulunan 5 adet rulmanın kestirim sonuçları gerçek KFÖ değerleri ile birlikte verilmiştir.




(a)




(b)



(c)



(d)




(e)


Şekil 4.19 : Birinci çalışma koşulundaki test rulmanlarının KFÖ tahminleri.

Grafiklerde görülen rulmana verilerinin aynı çalışma koşullarında farklı KFÖ değerlerindeki tahminleri verilmiştir. Hem eğitim hem de test veri kümesinde bulunan rulmanlarda kestirim yapılan değerlerinden aynı miktarda bulunmamaktadır. Eğitim veri kümesindeki rulmanların ömürlerinin sonları hepsinde mevcutken 28000 saniye


boyunca çalışan sadece bir adet rulman bulunmaktadır. Bu sebeple başlangıçtaki rulmanların örüntülerini yakalamak zor olmaktadır.




(a)




(b)



(c)



(d)




(e)

Şekil 4.20 : İkinci çalışma koşulundaki test rulmanlarının KFÖ tahminleri.

Şekil 4.20’de ikinci çalışma koşulunda test veri kümesinde bulunan rulmanların kestirimleri gösterilmiştir. Bu çalışma koşulunda rulmanlar 1650 rpm hızda ve 4200 N yükte çalıştırılmıştır. Bu çalışma koşulunda yapılan kestirimler değerlendirme metrik sonuçlarına göre daha yüksek kestirim oranına sahiptir. Elde edilen sonuçlarda

eđitim veri kümesinde etiketlerin eşit oranda olmaması sebebiyle etiketlerin öğrenme yeteneđi yeterli gelmemiştir. Ayrıca elde edilen sonuçlar incelendiđinde önerilen modelin yeteri kadar öğrenme gerçekleştirmediđi görülmektedir. Ancak test veri kümesinde bulunan rulmanların ömürlerinin sonlarına doğru KFÖ değerleri yakalanabilmektedir.



Şekil 4.21 : Üçüncü çalışma koşulundaki test rulmanının KFÖ tahmini.

Şekil 4.21'de üçüncü çalışma koşulunda test veri kümesinde bulunan rulmanın kestirimleri gösterilmiştir. Bu çalışma koşulunda rulmanlar 1500 rpm hızda ve 5000 N yükü çalıştırılmıştır. Test verisinde bulunan bu koşuldaki tek rulmanın ömrü diğerlerine göre kısadır ve önerilen model bu değerlerde altı farklı rulmanda eğitilmiştir. Elde edilen sonuçlara ve grafiđe göre rulmanın başlangıçtan ömrünün bitimine kadar KFÖ değeri yakın izlenmektedir. Test veri kümesinde bulunan tüm rulmanlar için önerilen model ile elde edilen KFÖ kestirimleri Çizelge 4.4'te verilmiştir.

Çizelge 4.4 : Önerilen model ile her rulman için elde edilen sonuçlar.

Test Rulmanları	Şimdiki zaman (s)	Gerçek KFÖ (s)	Kestirilen KFÖ (s)	Er	A	Skor
Rulman1_3	18010	5730	3488,33	39,12	0,25	-
Rulman1_4	11380	2890	2032,74	29,66	0,35	-
Rulman1_5	23010	1610	1272,07	20,98	0,48	-
Rulman1_6	23010	1460	592,72	59,4	0,12	-
Rulman1_7	15010	7570	146,82	98,06	0,03	-
Rulman2_3	12010	7530	7362,27	2,22	0,92	-
Rulman2_4	6110	1390	3976,03	-186	0	-
Rulman2_5	20010	3090	3019,22	2,29	0,92	-
Rulman2_6	5710	1290	1187,12	7,97	0,75	-
Rulman2_7	1710	580	4225,3	-628,7	0	-
Rulman3_3	3510	820	795,7	2,95	0,90	-
-	-	-	-	-	-	0,43

Çizelgede rulmanlar için elde edilen KFÖ değerleri farklı ömür süreleri için farklılık göstermektedir. Rulman2_5 ve Rulman2_6 gibi rulmanlarda istenilen ömür kestirimi yakın sonuçlarla elde edilmiştir. Ancak aynı çalışma koşulunda bulunan Rulman2_7 için ise istenen KFÖ değeri elde edilememiştir. Şekil 4.20e’de görüleceği gibi bu rulman için herhangi bir KFÖ değeri doğru olarak tahmin edilememiş ve elde edilen sonuçta yeterli gelmemiştir. Ancak aynı çalışma koşulunda bulunan 4.19a grafiğinde bazı gürültülü süreçlerde yapılan kestirimler yanlış olsa da genel itibari ile doğrusal bozulma eğrisine uygun şekilde ilerleme olmuştur. Elde edilen sonuçlar ile veri yarışması için hazırlanan değerlendirme metriği sonuçları Çizelge 4.4’te gösterilmiştir. Yapılan çalışmada mel spektrum öznelikleri kullanılmıştır. Ancak önerilen model yapısı öncesinde spektrum verileri ile de test edilmiş ve mel spektrum verilerine göre daha kötü sonuçlar elde edilmiştir. Bu sebeple bu çalışma kapsamında mel spektrumu kullanılmış ve önerilen model ile sonuçlar elde edilmiştir. Elde edilen skor değeri maksimum olarak her bir rulman ve genel sonuç için 1 iken önerilen derin öğrenme modeli ile 0.433 genel skor değeri elde edilmiştir.

4.5 Sonuçların Karşılaştırılması

Bu tez çalışması kapsamında KFÖ kestirimi için FEMTO-ST rulman veri kümesi kullanılmıştır. Bu veri kümesi üzerinde KFÖ kestirimi için veri temelli derin öğrenme tabanlı bir model önerilmiştir. Literatürde bu veri kümesi üzerinde yapılan çalışmalarda farklı yaklaşımlarda bulunulmuş, farklı senaryolar üzerinde modeller geliştirilmiştir. Bu veri kümesi PHM2012 konferansında veri yarışması için belirli bir senaryo ile buna uygun değerlendirme metrikleri birlikte paylaşılmıştır. Önerilen model ile elde edilen sonuçların karşılaştırması yapılırken literatürdeki çalışmalarda veri yarışmasındaki senaryoları kullananlar ele alınmış ve karşılaştırma yapılmıştır. Literatürde yapılan çalışmalar ile önerilen derin öğrenme modelinin Er değerlerine göre karşılaştırması Çizelge 4.5’te verilmiştir.

Çizelge 4.5 : Önerilen model ile var olan yöntemlerin sonuçlarının skor metriği ile karşılaştırılması.

Test	Er	Er[65]	Er[111]	Er[67]	Er[63]	Er[64]	Er[112]
Rulmanlar							
Rulman1_3	39,12	-1,04	43,28	15	37	54,73	4
Rulman1_4	29,66	85,86	62,06	27	80	38,69	0
Rulman1_5	20,98	-278,2	-22,98	-12	9	-99,4	54
Rulman1_6	59,4	19,17	21,23	8	-5	-120	46
Rulman1_7	98,06	-7,13	17,83	10	-2	70,65	60
Rulman2_3	2,22	10,49	37,84	-5	64	75,53	96
Rulman2_4	-186	51,79	-19,42	29	10	19,81	30
Rulman2_5	2,29	28,80	54,36	-37	-440	8,2	76
Rulman2_6	7,97	-20,93	-13,95	-12	49	17,87	36
Rulman2_7	-628,7	44,82	-55,17	-21	-317	1,69	100
Rulman3_3	2,95	-3,65	3,65	13	90	2,93	44
Skor	0,433	0,354	0,264	0,399	0,306	0,382	0,304

Çizelge incelendiğinde literatürde önerilen modeller her bir rulman için başarılı sonuçları vermemektedir. Hong ve ark. sunmuş oldukları çalışma test veri kümesindeki Rulman1_3 için en iyi sonucu verirken Rulman1_4 için ise Singleton ve ark. yapmış oldukları çalışma daha iyi sonuç vermiştir. Önermiş olduğumuz model ile Rulman2_5 ile Rulman2_6 ‘da ise literatüre göre çok daha iyi sonuçlar elde edilmiştir. Yapılan çalışmalarda rulman verilerinden çıkarılan özniteliklerin korelasyonu ile önerilen modelin öğrenme durumu elde edilen sonuçları etkilemektedir.

Yapılan KFÖ kestirimi çalışmasında literatürde bildirilen kestirim modellerine göre değerlendirme metriğinde diğer çalışmalardan daha iyi sonuçlar elde edilmiştir. Bu çalışmalar incelendiğinde önerilen yöntemler farklı çalışma koşullarında bulunan farklı rulmanlarda daha iyi sonuçlar verebilirken asimetric değerlendirme metriği tüm test rulmanlarında kıyaslandığında sonuçların ortalaması düşmektedir. Ayrıca literatürde farklı senaryolar ile rulman titreşim verilerinin incelenmesinde başarılı sonuçlar olsa da bu çalışmalar sadece belli çalışma koşullarını baz almaktadır. Farklı çalışmalarda ise eğitim veri kümesine test verilerinden rulmanlar eklenerek modellerin öğrenme yetenekleri arttırılmaktadır. Bu çalışmalar aynı senaryoda inceleme yapmadıkları için çizelgeye alınmamıştır.

5. TARTIŞMA VE GELECEK ÇALIŞMALAR

Bakım faaliyetleri geçmişten günümüze ihtiyaçlar doğrultusunda gelişerek gelmiştir. Yapılan ilk araçlarda meydana gelen arızaların bakımları arıza meydana geldikten sonra değişim ve düzeltme şeklinde olmaktadır. Bu bakım türü güvenlik gerektirmeyen araç veya sistemlerde diğer bakım yöntemlerine göre daha ucuz olması sebebiyle günümüzde de devam etmektedir. Gelişen teknoloji ve artan ekipman sayısı ile birlikte bunların güvenliği ve çalışma ömürleri önem kazanmaya başlamıştır. Böylelikle önleyici bakım faaliyetleri ortaya çıkmıştır. Ortaya çıkan endüstri devrimleri ile meydana gelen her arızanın kaydının alınmasına ve duraksamaların önüne geçmeye amaçlanmaktadır. Tutulan arıza ve duraksama kayıtları ile planlı veya koşullu bakımlar ortaya çıkmıştır. Böylelikle üretimde, makinelerin yoğun kullanıldığı yerlerde güvenilirlik esas alınarak arızadan önce bakımlar yapılmıştır.

Son endüstri devrimlerinde gelişen sensör teknolojileri ve hesaplama gücüyle meydana gelen arızalar analiz edilmektedir. Ayrıca sistemlerin ve üretim hatlarının dijital ikizleri oluşturulmakta ve böylelikle arızaların önüne geçmeye çalışılmaktadır. Sensör teknolojisinin gelişmesi ve hassas ölçümler alabilmesi ile sistem veya ekipmanlarından birçok sensör yardımıyla veriler toplanmaya başlanmıştır. Bu veriler kayıt altına alınmakta ve analizleri yapılmaktadır. Bu analizler ile arızanın ne olduğu ve ne zaman olacağı kestirilmeye çalışılmaktadır. Bu faaliyetlerin tamamı da kestirimci bakım çalışmalarını oluşturmaktadır.

Endüstri 4.0 ile birlikte makineleri durumlarını, sağlığını ve üretilen ürünlerin kalitesini izleyen birçok sensör kullanılmaktadır. Bu sensörler işlenmek ve değerlendirmek üzere büyük miktarda veriyi doğurmaktadır. Bu verilerden bakım zamanının doğru şekilde kestirimi ile hem makine ve sistemin güvenilirliği artırılmış olmakta hem de ölümcül olabilecek kazaların önüne geçilmektedir. Ayrıca bakım zamanının en uygun olacak şekilde tespit edilmesi ile gereksiz parça değişimi önlenmiş ve bakım maliyetleri düşürülmüş olacaktır. Bakım kestirimini yapabilmek için yüksek başarımda modellerin geliştirilmesi gerekmektedir.

Son 15 yılda makine öğrenimi ve alt kolu olan derin öğrenme alanında meydana gelen gelişmeler ile büyük verilerden anlamalı sonuçlar yüksek hassasiyet ile sağlanabilmektedir. Kestirimci bakım çalışmalarında sıklıkla kullanılan derin öğrenme yöntemleri ile arızaların teşhisi, arıza sınıflandırması, sistem sağlık durumu ve KFÖ

kestirimi daha hassas bir şekilde yapılabilir. KFÖ kestirimindeki başarımları ile bakım planlaması minimum duraksama ve minimum bakım maliyeti ile yapılabilir. Ayrıca bu verilerden arızanın kaynağı ve meydana gelen arızanın türünün kestirilmesi ile bakım için yapılan duraksama süresi azaltılabilir.

Derin öğrenme yöntemlerinin kestirimci bakım çalışmalarında kullanılması ile alana özgü uzmanlık bilgisine bağımlılık azalmıştır. Böylelikle verilerde bulunan ilintili özniteliklerin çıkarılması ve tespit edilmesi derin öğrenme yöntemleri ile gerçekleştirilmektedir. Derin öğrenme tekniklerinden son 5 yılda önerilen Öz-Dikkat katmanı ve bunu temel alan Dönüştürücü yapıları ile gerçekleştirilen kestirimler daha başarılı sonuçlar vermektedir. Öz-Dikkat katmanı ile ham verilerde veya ön işlem tabii olmuş kestirim verilerinde gerekli olan özniteliklere odaklanarak sınıflandırma veya KFÖ kestirimi yapılmaktadır. Bu çalışma kapsamında kestirimci bakım için KFÖ kestirimi yapılmıştır. KFÖ kestirimi için literatürde sıklıkla kullanılan ve PHM konferanslarında önerilmiş olan C-MAPSS uçak motoru veri kümesi ile FEMTO-ST rulman veri kümesi kullanılmıştır.

Tez çalışması kapsamında ilk olarak C-MAPSS uçak motoru veri kümesinde çalışılmıştır. Bu çalışma kapsamında uçak motorlarının farklı çalışma koşullarında ve farklı arızalardaki verileri 4 farklı senaryoda verilmiştir. Öz-Dikkat katmanı temelli ve ResNet katmanını içeren CSARN modeli KFÖ kestirimi için tasarlanmıştır. Literatürde de yer alan parçalı doğrusal bozulma modeli ile çalışılmıştır. Veriler kestirimi için kayan zaman penceresi yöntemi ile ön işleme tabii tutulmuştur. Her bir alt veri kümesinde farklı ömürlere sahip uçak motorları olması sebebiyle farklı boyutlu veriler ve modeller ile çalışılmıştır. Bu veri kümesi PHM2008 konferansında veri yarışması için hazırlanmıştır ve karşılaştırmaların yapılabilmesi için asimetric bir değerlendirme metriği önerilmiştir. Böylelikle önerilen modeller ile geç yapılan tahminlerin ölümcül sonuçlar doğurabilme durumuna göre daha fazla cezalandırma yapılması istenmiştir. Bakım zamanının kestiriminde önceliğin güvenilirlik olması sebebiyle yeni önerilen değerlendirme metriği önem taşımaktadır. Önerilen modelin eğitiminde bu ön koşul dikkate alınarak yeni asimetric bir kayıp fonksiyonu önerilmiştir. Bununla birlikte model yeni kayıp fonksiyonu ile eğitilmiştir. Model ile dört farklı alt veri kümesi üzerinde kestirimler yapılmıştır. Bu kestirimlerden daha basit senaryolara sahip olanlarda literatüre göre daha iyi sonuçlar elde edilmiştir. Bu çalışma kapsamında eğitim prosedürü değiştirilmemiştir Daha karmaşık yapıya sahip

veri kümelerinde ise eğitim prosedürünün değişmemesi ile literatüre göre adil sonuçlar elde edilmiştir.

Uçak motoru veri kümesinde KFÖ tahmini için önerilen derin öğrenme modelinin sonuçlar üzerindeki etkisi ayrıntılı olarak incelenmiştir. Model yapısı içerisinde bulunan Öz-Dikkat Katmanı, Gauss Gürültü Katmanı ve ResNet katmanının etkileri eğitim prosedürü değişmeden test edilmiştir. Her birinin ve birlikte olan etkilerinin farklı modeller üzerinden dört alt veri kümesinde eğitilip test edilerek gözlenmiştir. Buradan çıkarılan sonuca göre Öz-Dikkat katmanı ile oluşturacak modellerin daha iyi sonuçlar verebileceği gözlenmiştir.

Tez çalışması kapsamında ikinci olarak FEMTO-ST rulman veri kümesi kullanılmıştır. Bu çalışma kapsamında birçok döner makinada kullanılan rulmanların KFÖ kestirimi üzerinde çalışma yapılmıştır. Rulman veri kümesinde 17 adet rulmanın başlangıçtan arıza anına kadar titreşim verileri bulunmaktadır. Laboratuvar ortamında hazırlanan deney düzeneğinde rulmanları üç farklı çalışma hızı ve üç farklı yükte çalıştırılarak çalışma ömürleri test edilmiştir. Her bir rulman 2 titreşim sensörü ve bir adet sıcaklık sensörü ile izlenmiştir. Titreşim verileri 25.6 kHz ile örneklenmiş olup veriler yüksek frekanslarda bilgi barındırmaktadır. Bu sebeple veriler eğitilmeden önce ses verilerinde sıklıkla kullanılan Mel spektrogram işlemine tabi tutulmuştur. Böylelikle veriler hem zaman hem de mel frekans uzayında ifade edilmiştir. Ayrıca diğer çalışmada olduğu gibi kayan zaman penceresi uygulanmış ve geçmişe dair bilgilerden faydalanılması sağlanmıştır. Yeni veri kümesi Öz-Dikkat katmanını temel alan Dönüştürücü yapısı ile derin öğrenme tabanlı bir kestirim modeli sunulmuştur. Bu çalışma PHM2012 de öne sürülen eğitim ve test senaryosuna göre yapılmış ve model bu senaryoda olan 6 adet eğitim rulmanı ile eğitilmiştir. Geri kalan test kümesindeki 11 rulman ile test yapılmış elde edilen sonuçlarda literatür ile karşılaştırmalı olarak sunulmuştur. Rulman veri kümesi için veri yarışmasında asimetrik bir değerlendirme metriği önerilmiştir. Böylelikle geç tahminlerin önüne geçilmesi hedeflenmiştir. Önerilen model ile yapılan kestirimler bu değerlendirme metriğine göre yapılmış ve karşılaştırılmıştır. Test veri kümesinde bulunan 11 rulmana göre elde edilen skor değeri 0.433 olmuştur. Bu değer ile literatüre göre rulmanların ortalamasında daha başarılı sonuçlar elde edilmiştir.

PHM konferanslarında sunulan iki farklı veri kümesinde KFÖ kestirimi üzerinde çalışmalar yapılmıştır. Bu çalışmalar kapsamında veri temelli derin öğrenme modelleri

sunulmuştur. Derin öğrenme de yaşanan son yıllardaki gelişmeler ve bulunan algoritmalar önerilen modellerde kullanılmıştır. Her iki problem için Öz-Dikkat katmanını temel alan modeller tasarlanmıştır. Uçak motoru veri kümesinde farklı alt kümeleri için Öz-Dikkat katmanının etkisi incelenmiş ve model ile literatüre göre başarılı sonuçlar elde edilmiştir. Ayrıca bu veri kümesinde bakım kestirimi için daha uygun olan bir kestirim modeli tasarlanabilmesi için yeni bir kayıp fonksiyonu önerilmiştir. Böylelikle hem asimetrik değerlendirme metriğinde daha iyi sonuçlar elde edilmiş hem de sistemlerin bakıma alınma kararında ölümcül kazaların önüne geçilmesi sağlanmıştır. Rulman veri kümesinde Öz-Dikkat katmanını temel alan Dönüştürücü yapısı kullanılmış ve KFÖ kestiriminde veri temelli bir derin öğrenme modeli sunulmuştur. Rulmanlardan alınan titreşim verileri zaman uzayından frekans uzayına geçirilerek önışleme tabi tutulmuştur. Dönüştürücü yapısını temel alan derin öğrenme modeli ile KFÖ kestirimi yapılmıştır. 17 rulman verisinden 6 adeti veri yarışması senaryosuna uygun olacak şekilde eğitimde kullanılmış ve model eğitimi yapılmıştır. Kestirim yapılan değerlerin dengesiz dağılımı sebebiyle her rulmanın başlangıç değerleri uygun şekilde tespit edilememiştir. Ayrıca rulmanlar üç farklı çalışma koşulunda test edildikleri için ve her biri farklı başlangıç koşullarına sahip olduğu için farklı çalışma ömürlerine sahiptir. Her bir rulmanda çalışma durumlarına farklı tepkiler vermiştir. Önerilen model ile farklılıkların öğrenilmesi ve KFÖ kestiriminin doğru yapılması hedeflenmiştir. Asimetrik değerlendirme metriğine göre literatürden daha iyi sonuçlar elde edilmiştir.

Yapılan tez çalışması ile veri temelli derin öğrenme modelleri iki farklı veri kümesinde KFÖ kestirimi için kullanılmıştır. Yapılan kestirimler başarılı sonuçlar vermiş olsa da geliştirilmesi gerekmektedir. Özellikle arızalardan meydana gelebilecek ölümcül kazalardan kaçınabilmek ve en uygun bakım zamanını kestirerek bakım maliyetlerini düşürmek için modellerin geliştirilmesi gerekmektedir. Bununla birlikte Endüstri 4.0 ile beraber sensörler yardımıyla üretim sistemlerin izlenmesi hem bakım hem kalite için daha da önem arz eder hale gelmiştir. Toplanan veriler hem sistemlerin sağlık durumu hakkında bilgiler taşımakta hem de üretilen ürünlerin kalitesini kestirme de yardımcı olabilmektedir. Bu sebeple derin öğrenme tabanlı sistemlerin geliştirilmesi için arıza kaynaklı veriye ihtiyaç duyulmaktadır. Bu verilerin elde edilmesi ile bakım maliyetlerini düşürecek bakım planlamasını kestirimci bakım yardımıyla yapılabilir hale gelecektir.

Tez çalışması boyunca yapılan çalışmalar benzetim verileri veya laboratuvar ortamında gerçekleştirilen veriler üzerinde olmuştur. Kullanılabilecek kestirim modellerinin yapısı hakkında bilgi vermişlerdir. Gelecek çalışmalarda deneysel çalışmalar ile gerçekleştirilmesi zor olan uçak motoru gibi benzetim verilerinde daha hassas modellerin geliştirilmesi hedeflenmektedir. Deneysel altyapısının kurulabileceği rulman verileri gibi yapılarda ise deney düzeneğinin oluşturulması, arızaların tespiti ve KFÖ kestirimi üzerine farklı senaryolar ile çalışmalar yapılacaktır. Ayrıca rulman döner ekipmanı birçok makinenin içinde olması sebebiyle gerçek dünya problemlerinden alınan veriler üzerinde de çalışmalar yapılabilecektir. Bununla birlikte gelişen elektrikli araç teknoloji ve bunun temel bileşeni olan bataryaların ver temelli bir yapı ile KFÖ kestirimi üzerinde durulacaktır.



KAYNAKLAR

- [1] **Kirazlılar, B.** (2007). *Endüstriyel bakım: kestirimci ve önleyici bakımın temelleri... ve ustaların pratik metotları*. Birsen Yayınevi.
- [2] **Peng, Y., Dong, M., & Zuo, M. J.** (2010). Current status of machine prognostics in condition-based maintenance: a review. *The International Journal of Advanced Manufacturing Technology*, 50, 297–313.
- [3] **Hashemian, H. M.** (2010). State-of-the-art predictive maintenance techniques. *IEEE Transactions on Instrumentation and Measurement*, 60, 226–236.
- [4] **Aventics and Ifm on predictive maintenance.** (2001). Retrieved June 15, 2023, from <https://www.intech-net.com/sps-2016-aventics-and-ifm-on-predictive-maintenance/>
- [5] **Wang, L., Chu, J., & Wu, J.** (2007). Selection of optimum maintenance strategies based on a fuzzy analytic hierarchy process. *International journal of production economics*, 107, 151–163.
- [6] **Tu, Y.** (1995). Decision support system for equipment diagnosis and maintenance management: An artificial intelligent approach. *Research Proposal, City University of Hong Kong, HK*.
- [7] **Henriquez, P., Alonso, J. B., Ferrer, M. A., & Travieso, C. M.** (2013). Review of automatic fault diagnosis systems using audio and vibration signals. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 44, 642–652.
- [8] **Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L., & Siegel, D.** (2014). Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications. *Mechanical systems and signal processing*, 42, 314–334.
- [9] **Selcuk, S.** (2017). Predictive maintenance, its implementation and latest trends. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 231, 1670–1679.
- [10] **Butte, S., Prashanth, A. R., & Patil, S.** (2018). Machine learning based predictive maintenance strategy: a super learning approach with deep neural networks. *2018 IEEE Workshop on Microelectronics and Electron Devices (WMED)*, (s. 1–5).
- [11] **Liu, L., Logan, K. P., Cartes, D. A., & Srivastava, S. K.** (2007). Fault detection, diagnostics, and prognostics: software agent solutions. *IEEE Transactions on Vehicular Technology*, 56, 1613–1622.
- [12] **Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. d., Basto, J. P., & Alcalá, S. G.** (2019). A systematic literature review of machine learning

- methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024.
- [13] **Yurtsever, M.** (2020). Makine öğrenmesi ve derin öğrenme yöntemleri ile titreşim analizi tabanlı arıza teşhis ve kestirimci bakım sistem tasarımı.
- [14] **Saxena, A., Goebel, K., Simon, D., & Eklund, N.** (2008). Damage propagation modeling for aircraft engine run-to-failure simulation. *2008 international conference on prognostics and health management*, (s. 1–9).
- [15] **Nectoux, P., Gouriveau, R., Medjaher, K., Ramasso, E., Chebel-Morello, B., Zerhouni, N., & Varnier, C.** (2012). PRONOSTIA: An experimental platform for bearings accelerated degradation tests. *IEEE International Conference on Prognostics and Health Management, PHM'12.*, (s. 1–8).
- [16] **Lee, J., Qiu, H., Yu, G., Lin, J., & others.** (2007). Bearing data set. *IMS, University of Cincinnati, NASA Ames Prognostics Data Repository, Rexnord Technical Services.*
- [17] **Lessmeier, C., Kimotho, J. K., Zimmer, D., & Sextro, W.** (2016). Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification. *PHM Society European Conference*, 3.
- [18] **Li, S.-Y., & Gu, K.-R.** (2019). Smart fault-detection machine for ball-bearing system with chaotic mapping strategy. *Sensors*, 19, 2178.
- [19] *Case Western Reserve University Bearing Dataset.* (2012). Retrieved June 15, 2023, from <https://engineering.case.edu/bearingdatacenter>
- [20] **Agogino, A., & Goebel, K.** (2007). Milling data set. *NASA Ames Prognostics Data Repository, BEST Lab: Berkeley, CA, USA.*
- [21] **Li, X., Ding, Q., & Sun, J.-Q.** (2018). Remaining useful life estimation in prognostics using deep convolution neural networks. *Reliability Engineering & System Safety*, 172, 1–11.
- [22] **Zhang, X., Guo, Y., Shanguan, H., Li, R., Wu, X., & Wang, A.** (2023). Predicting remaining useful life of a machine based on embedded attention parallel networks. *Mechanical Systems and Signal Processing*, 192, 110221.
- [23] **Liao, L.** (2013). Discovering prognostic features using genetic programming in remaining useful life prediction. *IEEE Transactions on Industrial Electronics*, 61, 2464–2472.
- [24] **Lei, Y., Li, N., Gontarz, S., Lin, J., Radkowski, S., & Dybala, J.** (2016). A model-based method for remaining useful life prediction of machinery. *IEEE Transactions on reliability*, 65, 1314–1326.
- [25] **Saha, B., & Goebel, K.** (2011). Model adaptation for prognostics in a particle filtering framework. *International Journal of Prognostics and Health Management Volume 2 (color)*, 61.

- [26] **Liao, L., & Köttig, F.** (2016). A hybrid framework combining data-driven and model-based methods for system remaining useful life prediction. *Applied Soft Computing*, *44*, 191–199.
- [27] **Baraldi, P., Compare, M., Saucio, S., & Zio, E.** (2013). Ensemble neural network-based particle filtering for prognostics. *Mechanical Systems and Signal Processing*, *41*, 288–300.
- [28] **Sateesh Babu, G., Zhao, P., & Li, X.-L.** (2016). Deep convolutional neural network based regression approach for estimation of remaining useful life. *Database Systems for Advanced Applications: 21st International Conference, DASFAA 2016, Dallas, TX, USA, April 16-19, 2016, Proceedings, Part I 21*, (s. 214–228).
- [29] **Zhang, C., Lim, P., Qin, A. K., & Tan, K. C.** (2016). Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics. *IEEE transactions on neural networks and learning systems*, *28*, 2306–2318.
- [30] **Li, F., Zhang, L., Chen, B., Gao, D., Cheng, Y., Zhang, X., . . . Peng, J.** (2018). A light gradient boosting machine for remaining useful life estimation of aircraft engines. *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, (s. 3562–3567).
- [31] **Mathew, V., Toby, T., Singh, V., Rao, B. M., & Kumar, M. G.** (2017). Prediction of Remaining Useful Lifetime (RUL) of turbofan engine using machine learning. *2017 IEEE international conference on circuits and systems (ICCS)*, (s. 306–311).
- [32] **Li, Z., Goebel, K., & Wu, D.** (2019). Degradation modeling and remaining useful life prediction of aircraft engines using ensemble learning. *Journal of Engineering for Gas Turbines and Power*, *141*.
- [33] **Lim, P., Goh, C. K., & Tan, K. C.** (2016). A time window neural network based framework for remaining useful life estimation. *2016 international joint conference on neural networks (IJCNN)*, (s. 1746–1753).
- [34] **Jayasinghe, L., Samarasinghe, T., Yuenv, C., Low, J. C., & Ge, S. S.** (2019). Temporal convolutional memory networks for remaining useful life estimation of industrial machinery. *2019 IEEE International Conference on Industrial Technology (ICIT)*, (s. 915–920).
- [35] **Wen, L., Dong, Y., & Gao, L.** (2019). A new ensemble residual convolutional neural network for remaining useful life estimation. *Math. Biosci. Eng.*, *16*, 862–880.
- [36] **Wang, B., Lei, Y., Li, N., & Yan, T.** (2019). Deep separable convolutional network for remaining useful life prediction of machinery. *Mechanical systems and signal processing*, *134*, 106330.
- [37] **Heimes, F. O.** (2008). Recurrent neural networks for remaining useful life estimation. *2008 international conference on prognostics and health management*, (s. 1–6).
- [38] **Zheng, S., Ristovski, K., Farahat, A., & Gupta, C.** (2017). Long short-term memory network for remaining useful life estimation. *2017 IEEE*

international conference on prognostics and health management (ICPHM), (s. 88–95).

- [39] **Wang, J., Wen, G., Yang, S., & Liu, Y.** (2018). Remaining useful life estimation in prognostics using deep bidirectional lstm neural network. *2018 Prognostics and System Health Management Conference (PHM-Chongqing)*, (s. 1037–1042).
- [40] **Hsu, C.-S., & Jiang, J.-R.** (2018). Remaining useful life estimation using long short-term memory deep learning. *2018 IEEE International Conference on Applied System Invention (ICASI)*, (s. 58–61).
- [41] **Huang, C.-G., Huang, H.-Z., & Li, Y.-F.** (2019). A bidirectional LSTM prognostics method under multiple operational conditions. *IEEE Transactions on Industrial Electronics*, *66*, 8792–8802.
- [42] **Yu, W., Kim, I. Y., & Mechefske, C.** (2019). Remaining useful life estimation using a bidirectional recurrent neural network based autoencoder scheme. *Mechanical Systems and Signal Processing*, *129*, 764–780.
- [43] **Miao, H., Li, B., Sun, C., & Liu, J.** (2019). Joint learning of degradation assessment and RUL prediction for aeroengines via dual-task deep LSTM networks. *IEEE Transactions on Industrial Informatics*, *15*, 5023–5032.
- [44] **Zhang, Y., Hutchinson, P., Lieven, N. A., & Nunez-Yanez, J.** (2020). Remaining useful life estimation using long short-term memory neural networks and deep fusion. *IEEE Access*, *8*, 19033–19045.
- [45] **Al-Dulaimi, A., Zabihi, S., Asif, A., & Mohammadi, A.** (2019). A multimodal and hybrid deep neural network model for remaining useful life estimation. *Computers in Industry*, *108*, 186–196.
- [46] **Liu, H., Liu, Z., Jia, W., & Lin, X.** (2020). Remaining useful life prediction using a novel feature-attention-based end-to-end approach. *IEEE Transactions on Industrial Informatics*, *17*, 1197–1207.
- [47] **Chen, Z., Wu, M., Zhao, R., Guretno, F., Yan, R., & Li, X.** (2020). Machine remaining useful life prediction via an attention-based deep learning approach. *IEEE Transactions on Industrial Electronics*, *68*, 2521–2531.
- [48] **Ruiz-Tagle Palazuelos, A., Droguett, E. L., & Pascual, R.** (2020). A novel deep capsule neural network for remaining useful life estimation. *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*, *234*, 151–167.
- [49] **Li, J., Li, X., & He, D.** (2019). A directed acyclic graph network combined with CNN and LSTM for remaining useful life prediction. *IEEE Access*, *7*, 75464–75475.
- [50] **Kong, Z., Cui, Y., Xia, Z., & Lv, H.** (2019). Convolution and long short-term memory hybrid deep neural networks for remaining useful life prognostics. *Applied Sciences*, *9*, 4156.
- [51] **Da Costa, P. R., Akcay, A., Zhang, Y., & Kaymak, U.** (2019). Attention and long short-term memory network for remaining useful lifetime

- predictions of turbofan engine degradation. *International journal of prognostics and health management*, 10.
- [52] **Ragab, M., Chen, Z., Wu, M., Kwoh, C.-K., Yan, R., & Li, X.** (2021). Attention-based sequence to sequence model for machine remaining useful life prediction. *Neurocomputing*, 466, 58–68.
- [53] **Al-Dulaimi, A., Asif, A., & Mohammadi, A.** (2020). Noisy parallel hybrid model of NBGRU and NCNN architectures for remaining useful life estimation. *Quality Engineering*, 32, 371–387.
- [54] **AlDulaimi, A., Mohammadi, A., & Asif, A.** (2020). The Noisy Multipath Parallel Hybrid Model for Remaining Useful Life Estimation (NMPM). *Annual Conference of the PHM Society*, 12, s. 10–10.
- [55] **Xia, J., Feng, Y., Lu, C., Fei, C., & Xue, X.** (2021). LSTM-based multi-layer self-attention method for remaining useful life estimation of mechanical systems. *Engineering Failure Analysis*, 125, 105385.
- [56] **Tan, W. M., & Teo, T. H.** (2021). Remaining useful life prediction using temporal convolution with attention. *Ai*, 2, 48–70.
- [57] **Park, Y.-I., Song, J., & Kang, S.-J.** (2022). Parallel Attention Network using Vector with High Correlation with Label for Remaining Useful Life Estimation. *AAAI 2022 Workshop on AI for Design and Manufacturing (ADAM)*.
- [58] **Remadna, I., Terrissa, L. S., Ayad, S., & Zerhouni, N.** (2021). RUL estimation enhancement using hybrid deep learning methods. *International Journal of Prognostics and Health Management*, 12.
- [59] **Chen, Y., Peng, G., Zhu, Z., & Li, S.** (2020). A novel deep learning method based on attention mechanism for bearing remaining useful life prediction. *Applied Soft Computing*, 86, 105919.
- [60] **Ren, L., Cui, J., Sun, Y., & Cheng, X.** (2017). Multi-bearing remaining useful life collaborative prediction: A deep learning approach. *Journal of Manufacturing Systems*, 43, 248–256.
- [61] **Loutas, T. H., Roulias, D., & Georgoulas, G.** (2013). Remaining useful life estimation in rolling bearings utilizing data-driven probabilistic E-support vectors regression. *IEEE Transactions on Reliability*, 62, 821–832.
- [62] **Cheng, C., Ma, G., Zhang, Y., Sun, M., Teng, F., Ding, H., & Yuan, Y.** (2020). A deep learning-based remaining useful life prediction approach for bearings. *IEEE/ASME transactions on mechatronics*, 25, 1243–1254.
- [63] **Sutrisno, E., Oh, H., Vasan, A. S., & Pecht, M.** (2012). Estimation of remaining useful life of ball bearings using data driven methodologies. *2012 ieee conference on prognostics and health management*, (s. 1–7).
- [64] **Hinchi, A. Z., & Tkiouat, M.** (2018). Rolling element bearing remaining useful life estimation based on a convolutional long-short-term memory network. *Procedia Computer Science*, 127, 123–132.

- [65] **Hong, S., Zhou, Z., Zio, E., & Hong, K.** (2014). Condition assessment for the performance degradation of bearing based on a combinatorial feature extraction method. *Digital Signal Processing*, 27, 159–166.
- [66] **Cheng, H., Kong, X., Chen, G., Wang, Q., & Wang, R.** (2021). Transferable convolutional neural network based remaining useful life prediction of bearing under multiple failure behaviors. *Measurement*, 168, 108286.
- [67] **Ren, L., & Lv, W.** (2016). Remaining useful life estimation of rolling bearings based on sparse representation. *2016 7th International Conference on Mechanical and Aerospace Engineering (ICMAE)*, (s. 209–213).
- [68] **Zhang, W., Peng, G., Li, C., Chen, Y., & Zhang, Z.** (2017). A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals. *Sensors*, 17, 425.
- [69] **Zhang, W., Li, C., Peng, G., Chen, Y., & Zhang, Z.** (2018). A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load. *Mechanical systems and signal processing*, 100, 439–453.
- [70] **Chen, M., Challita, U., Saad, W., Yin, C., & Debbah, M.** (2019). Artificial neural networks-based machine learning for wireless networks: A tutorial. *IEEE Communications Surveys & Tutorials*, 21, 3039–3071
- [71] **Asif, A., Al-Dulaimi, A., & Mohammadi, A.** (2020). *Degradation Modeling and Remaining Useful Life Estimation: From Statistical Signal Processing to Deep Learning Models*. Ph.D. dissertation, Concordia University.
- [72] **Ahmadzadeh, F., & Lundberg, J.** (2014). Remaining useful life estimation. *International Journal of System Assurance Engineering and Management*, 5, 461–474.
- [73] **Tkáč, M., & Verner, R.** (2016). Artificial neural networks in business: Two decades of research. *Applied Soft Computing*, 38, 788–804.
- [74] **Tenney, A. S., Glauser, M. N., Ruscher, C. J., & Berger, Z. P.** (2020). Application of artificial neural networks to stochastic estimation and jet noise modeling. *AIAA journal*.
- [75] **Ongsulee, P.** (2017). Artificial intelligence, machine learning and deep learning. *2017 15th international conference on ICT and knowledge engineering (ICT&KE)*, (s. 1–6).
- [76] **Károly, A. I., Fullér, R., & Galambos, P.** (2018). Unsupervised clustering for deep learning: A tutorial survey. *Acta Polytechnica Hungarica*, 15, 29–53.
- [77] **Shrestha, A., & Mahmood, A.** (2019). Review of deep learning algorithms and architectures. *IEEE access*, 7, 53040–53065.
- [78] **Mosavi, A., Faghan, Y., Ghamisi, P., Duan, P., Ardabili, S. F., Salwana, E., & Band, S. S.** (2020). Comprehensive review of deep reinforcement learning methods and applications in economics. *Mathematics*, 8, 1640.
- [79] **Hendrycks, D., & Gimpel, K.** (2016). Gaussian error linear units (gelus). *arXiv preprint arXiv:1606.08415*.

- [80] **Aggarwal, C. C.** (2018). *Neural Networks and Deep Learning*. Springer International Publishing. doi:10.1007/978-3-319-94463-0
- [81] **LeCun, Y., Boser, B., Denker, J., Henderson, D., Howard, R., Hubbard, W., & Jackel, L.** (1989). Handwritten digit recognition with a back-propagation network. *Advances in neural information processing systems*, 2.
- [82] **Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2012). ImageNet Classification with Deep Convolutional Neural Networks. F. Pereira, C. J. Burges, L. Bottou, & K. Q. Weinberger (Dü.), *Advances in Neural Information Processing Systems*
- [83] **LeCun, Y., Bengio, Y., & Hinton, G.** (2015). Deep learning. *nature*, 521, 436–444.
- [84] **Dos Santos, C., & Gatti, M.** (2014). Deep convolutional neural networks for sentiment analysis of short texts. *Proceedings of COLING 2014, the 25th international conference on computational linguistics: technical papers*, (s. 69–78).
- [85] **Abdel-Hamid, O., Mohamed, A.-r., Jiang, H., & Penn, G.** (2012). Applying convolutional neural networks concepts to hybrid NN-HMM model for speech recognition. *2012 IEEE international conference on Acoustics, speech and signal processing (ICASSP)*, (s. 4277–4280).
- [86] **Labati, R. D., Muñoz, E., Piuri, V., Sassi, R., & Scotti, F.** (2019). Deep-ECG: Convolutional neural networks for ECG biometric recognition. *Pattern Recognition Letters*, 126, 78–85.
- [87] **Siddique, N., Paheding, S., Elkin, C. P., & Devabhaktuni, V.** (2021). U-net and its variants for medical image segmentation: A review of theory and applications. *Ieee Access*, 9, 82031–82057.
- [88] **Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., & Gao, R. X.** (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213–237.
- [89] **Rahimpour, A.** (2019). Attention Mechanism for Recognition in Computer Vision
- [90] **Xue, B., Xu, Z.-b., Huang, X., & Nie, P.-c.** (2021). Data-driven prognostics method for turbofan engine degradation using hybrid deep neural network. *Journal of Mechanical Science and Technology*, 35, 5371–5387.
- [91] **Ba, J., Mnih, V., & Kavukcuoglu, K.** (2014). Multiple object recognition with visual attention. *arXiv preprint arXiv:1412.7755*.
- [92] **Bahdanau, D., Cho, K., & Bengio, Y.** (2014). Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*.
- [93] **Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., . . . Polosukhin, I.** (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- [94] **Nguyen, T. T.** (2019). *Machine translation with transformers*. Master's thesis.

- [95] **Frederick, D. K., DeCastro, J. A., & Litt, J. S.** (2007). *User's guide for the commercial modular aero-propulsion system simulation (C-MAPSS)*. Tech. rep.
- [96] **Wu, Y., Yuan, M., Dong, S., Lin, L., & Liu, Y.** (2018). Remaining useful life estimation of engineered systems using vanilla LSTM neural networks. *Neurocomputing*, 275, 167–179.
- [97] **He, K., Zhang, X., Ren, S., & Sun, J.** (2016). Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*, (s. 770–778).
- [98] **Kingma, D. P., & Ba, J.** (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- [99] **Yang, H., Zhao, F., Jiang, G., Sun, Z., & Mei, X.** (2019). A novel deep learning approach for machinery prognostics based on time windows. *Applied Sciences*, 9, 4813.
- [100] **Al-Dulaimi, A., Zabihi, S., Asif, A., & Mohammed, A.** (2020). NBLSTM: Noisy and hybrid convolutional neural network and BLSTM-Based deep architecture for remaining useful life estimation. *Journal of Computing and Information Science in Engineering*, 20, 021012.
- [101] **Song, J. W., Park, Y. I., Hong, J.-J., Kim, S.-G., & Kang, S.-J.** (2021). Attention-based bidirectional LSTM-CNN model for remaining useful life estimation. *2021 IEEE International Symposium on Circuits and Systems (ISCAS)*, (s. 1–5).
- [102] **Jin, R., Chen, Z., Wu, K., Wu, M., Li, X., & Yan, R.** (2022). Bi-LSTM-based two-stream network for machine remaining useful life prediction. *IEEE Transactions on Instrumentation and Measurement*, 71, 1–10.
- [103] **Zhang, J., Jiang, Y., Wu, S., Li, X., Luo, H., & Yin, S.** (2022). Prediction of remaining useful life based on bidirectional gated recurrent unit with temporal self-attention mechanism. *Reliability Engineering & System Safety*, 221, 108297.
- [104] **Liu, L., Song, X., & Zhou, Z.** (2022). Aircraft engine remaining useful life estimation via a double attention-based data-driven architecture. *Reliability Engineering & System Safety*, 221, 108330.
- [105] **Duan, Y., Li, H., He, M., & Zhao, D.** (2021). A BiGRU autoencoder remaining useful life prediction scheme with attention mechanism and skip connection. *IEEE Sensors Journal*, 21, 10905–10914.
- [106] **Xue, B., Xu, Z.-b., Huang, X., & Nie, P.-c.** (2021). Data-driven prognostics method for turbofan engine degradation using hybrid deep neural network. *Journal of Mechanical Science and Technology*, 35, 5371–5387.
- [107] **Li, H., Zhao, W., Zhang, Y., & Zio, E.** (2020). Remaining useful life prediction using multi-scale deep convolutional neural network. *Applied Soft Computing*, 89, 106113.
- [108] **Lei, Y., Li, N., Guo, L., Li, N., Yan, T., & Lin, J.** (2018). Machinery health prognostics: A systematic review from data acquisition to RUL prediction. *Mechanical systems and signal processing*, 104, 799–834.

- [109] **Hanilçi, C.** (2013). *Konuşmacı tanımada map uyarlamalı sınıflandırıcılar*. Ph.D. dissertation, Bursa Uludag University (Turkey).
- [110] **Radford, A., Kim, J. W., Xu, T., Brockman, G., McLeavey, C., & Sutskever, I.** (2022). Robust speech recognition via large-scale weak supervision. *arXiv preprint arXiv:2212.04356*.
- [111] **Guo, L., Li, N., Jia, F., Lei, Y., & Lin, J.** (2017). A recurrent neural network based health indicator for remaining useful life prediction of bearings. *Neurocomputing*, 240, 98–109.
- [112] **Singleton, R. K., Strangas, E. G., & Aviyente, S.** (2014). Extended Kalman filtering for remaining-useful-life estimation of bearings. *IEEE Transactions on Industrial Electronics*, 62, 1781–1790.



ÖZGEÇMİŞ

TARANMIŞ
VESİKALIK
FOTOĞRAF

Ad-Soyad : Adem AVCI

Doğum Tarihi ve Yeri :

E-posta :

ÖĞRENİM DURUMU:

- **Lisans** : 2014, Uludağ Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği
- **Yüksek Lisans** : 2017, Bursa Teknik Üniversitesi, Elektrik Elektronik Mühendisliği

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

- Avcı, A., & Acir, N. (2020, October). Remaining useful life estimation with parallel convolutional neural networks on predictive maintenance applications. In 2020 28th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE
- Adem, AVCI, & Nurettin, ACIR. (2023). Remaining Useful Life Estimation via Cascaded Self-Attention and ResNet Models. Journal of Innovative Science and Engineering, 7(1), 88-105.

DİĞER ESERLER, SUNUMLAR VE PATENTLER:

- Kocakulak, M., Avcı, A., & Acir, N. (2023). Automated vein verification using self-attention-based convolutional neural networks. Expert Systems with Applications, 120550.
- Avcı, A., Acir, N., Günes, E., & Turan, S. (2019, April). Quality Determination by Using Support Vector Machine in Gas Welding Applications. In 2019 27th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- Aydemir, G., Avcı, A., Kocakulak, M., & Bekiryazıcı, T. (2021, June). Ensemble of LSTM Networks for Fault Detection, Classification, and Root Cause

Identification in Quality Control Line. In PHM Society European Conference (Vol. 6, No. 1, pp. 6-6).

- Aydemir, G., Kurnaz, O., Bekiryazıcı, T., Avcı, A., & Kocakulak, M. (2021, November). Driver Drowsiness Detection using MobileNets and Long Short-term Memory. In 2021 13th International Conference on Electrical and Electronics Engineering (ELECO) (pp. 220-223). IEEE.
- Avcı, A., Kocakulak, M., & Acır, N. (2019, November). Convolutional neural network designs for finger-vein-based biometric identification. In 2019 11th International Conference on Electrical and Electronics Engineering (ELECO) (pp. 580-584). IEEE.

