KESTİRİMCİ BAKIMDA HİBRİT PROGNOSTİK YAKLAŞIMLAR KULLANILARAK KALAN FAYDALI ÖMÜR TAHMİNİ

Kıymet ENSARİOĞLU

T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

KESTİRİMCİ BAKIMDA HİBRİT PROGNOSTİK YAKLAŞIMLAR KULLANILARAK KALAN FAYDALI ÖMÜR TAHMİNİ

Kıymet ENSARİOĞLU
000-303-558-803

Prof. Dr. Erdal EMEL
(Danışman)

Prof. Dr. Tülin İNKAYA
(Eş Danışman)

DOKTORA TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2024

ÖZET

Doktora Tezi

KESTİRİMCİ BAKIMDA HİBRİT PROGNOSTİK YAKLAŞIMLAR KULLANILARAK KALAN FAYDALI ÖMÜR TAHMİNİ
Kıymet ENSARİOĞLU

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Erdal EMEL

Kalan Faydalı Ömür'ün (RUL) doğru bir şekilde tahmin edilmesi, turbo fan motorlarının prognostiğindeki en zor sorunlardan biridir. Son dönemlerde, turbo fan motorlarının RUL tahmininde kullanılan yöntemler ağırlıklı olarak veri odaklı modelleri içermektedir. Sensör verilerine uygulanan önişlemler prognostik modellerin daha iyi performans göstermesi için gereklidir. Turbo fan motorları üzerine yapılan çalışmaların birçoğunda, normal/sağlıklı çalışma süresince sabit bir başlangıç RUL değeri ile başlayan ve belirli bir kırılma noktasından sonra azalan parçalı-doğrusal (PwL) etiketleme yöntemi kullanır. Bu çalışmada RUL tahmini için öznitelik oluşturma, değişim noktası algılama tabanlı PwL etiketlemesi ve 1D-CNN-LSTM (Tek boyutlu- Evrişimli Sinir Ağları -Uzun Kısa Dönemli Bellek) hibrit sinir ağı modelini kullanan prognostik bir prosedür tasarlanmıştır. Tasarlanan prosedür C-MAPSS veri setinin bir alt veri seti olan FD001 üzerinde değerlendirilmiştir. Deneysel sonuçlar, yeni oluşturulan fark özniteliğinin girdi olarak kullanılmadığı modeller ve geleneksel makine öğrenmesi ile erken dönem derin öğrenme metotlarının kullanıldığı sinir ağı modelleriyle karşılaştırılmıştır. Bununla birlikte literatürde benzer metotları kullanan diğer çalışmalarla da karşılaştırılmıştır. Yapılan çalışmanın temel katkıları (i) oluşturulan yeni fark özniteliğinin tahmin performansını iyileştirmesi (ii) CNN'in öznitelik çıkarma yeteneğinin sinir ağının performansını iyileştirmesidir. Önerilen prosedür, turbo fan motorlarının RUL tahminini gerçek hayat uygulamasına yaklaştırmış ve motorlarının erken çalışma dönemlerinde daha doğru tahmin sonuçlarına olanak sağlamıştır.

Anahtar Kelimeler: kestirimci bakım, makine öğrenmesi, hibrit, kalan faydalı ömür
2024, x + 75 sayfa.

ABSTRACT

PhD Thesis

REMAINING USEFUL LIFE ESTIMATION USING HYBRID PROGNOSTIC APPROACHES FOR PREDICTIVE MAINTENANCE

Kıymet ENSARİOĞLU

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Industrial Engineering

Supervisor: Prof. Dr. Erdal EMEL

Accurate Remaining Useful Life (RUL) prediction is one of the most challenging problems in the prognostics of turbofan engines. Recently, RUL prediction methods of turbofan engines mainly involve data-driven models. Preprocessing the sensor data is essential for the performance of the prognostic models. Most studies on turbofan engines use piece-wise linear (PwL) labeling, which starts with a constant initial RUL value in normal/healthy operational mode. In this paper, we design a prognostic procedure that uses feature construction, change point detection-based PwL labeling, and 1D-CNN-LSTM (One-dimensional-Convolutional Neural Network-Long Short-Term Memory) hybrid neural network model for RUL prediction. The procedure is evaluated on the subset FD001 of the C-MAPSS dataset. Experimental results are compared with models without adding new difference features and with neural network models using traditional machine learning and deep learning models. Also, they are compared to the studies that use similar approaches. The main contributions of the study are (i) Performance improvement through feature construction and (ii) Use of CNN's feature extraction capability to improve the performance of the neural network. The proposed procedure makes the RUL prediction problem more realistic and enhances more accurate RUL estimation in the early operating stages of turbofan engines.

Key words: predictive maintenance, advanced machine learning, hybrid, RUL
2024, x + 75 pages.

TEŞEKKÜR

Bu doktora tezinin hazırlanması sürecinde bana değerli bilgi ve tecrübeleri ile yol gösteren ve destek olan tez danışmanım Prof. Dr. Erdal EMEL'e ve eş danışmanım Prof. Dr. Tülin İNKAYA'ya en içten teşekkürlerimi sunarım.

Tez komitemde yer alan değerli hocalarım Prof. Dr. Ali Yurdun ORBAK ve Doç. Dr. Fuat KOSANOĞLU'na bu süreçteki destekleri için teşekkürü borç bilirim.

Tez sürecine birlikte başladığımız ancak erken yaşta ani bir şekilde kaybettiğimiz danışmanım Prof. Dr. CENK ÖZMUTLU'yu anarak, onun kıymetli rehberliği ve tecrübeleriyle bana kattığı değerler için minnettarlığımı ifade etmek isterim.

Uzun ve meşakkatli tez çalışmalarım süresince verdikleri destek, gösterdikleri sabır ve fedakârlık ile her zaman yanımda olan eşim ÜMRE ENSARİOĞLU'na ve kızım ECE ENSARİOĞLU'na, ayrıca bu süreçte desteklerini esirgemeyen annem MUALLA DÖNMEZ'e ve babam MESUT DÖNMEZ'e teşekkürlerimi sunarım.

Kıymet ENSARİOĞLU
…/…/…….

İÇİNDEKİLER

Sayfa

ÖZET....iii
ABSTRACT....iv
TEŞEKKÜR....v
SİMGELER ve KISALTMALAR DİZİNİ....vii
ŞEKİLLER DİZİNİ....ix
ÇİZELGELER DİZİNİ....x
1. GİRİŞ....1
2. KAYNAK ÖZETLERİ....9
3. MATERYAL ve YÖNTEM....19
3.1. Materyal....19
3.2. Yöntem....21
3.2.1 Evrişimli sinir ağları (CNN)....22
3.2.2. Yinelemeli sinir ağları (RNN) ve uzun-kısa vadeli bellek (LSTM)....26
3.2.3. Otokodlayıcılar....29
3.2.4. Öznitelik mühendisliği....30
3.2.5. Değişim noktası tespiti....33
3.2.6. Önerilen prognostik prosedür....37
3.2.7. Önerilen sinirsel ağ yapısı....39
3.2.8. Değerlendirme metrikleri....41
4. BULGULAR ve TARTIŞMA....43
4.1. Bulgular....43
4.1.2. Veri ön işleme ve öznitelik seçimi....43
4.1.3. Otokodlayıcı tabanlı öznitelik çıkarma....46
4.1.4. Kayan zaman penceresi ile işleme....48
4.1.5. Değişim noktası temelli hedef değişken etiketleme....49
4.1.6. Öznitelik oluşturma....52
4.1.7 Ağ yapılandırma ve hiper parametre ayarlama....54
4.2. Deneysel Sonuçlar ve Tartışma....58
4.2.1. Farklı sinir ağı mimarilerinin için tahmin performansının karşılaştırması....58
4.2.2. Değişim noktası tespiti yöntemlerinin değerlendirilmesi....62
4.2.3. Önerilen fark temelli öznitelik oluşturma yaklaşımın değerlendirilmesi....62
4.2.4. İlgili çalışmalarla karşılaştırma....64
5. SONUÇ....66
KAYNAKLAR....68
ÖZGEÇMİŞ....75

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
φ	Aktivasyon Fonksiyonu
τ	Değişim Noktası
ϕ	Havuzlama Fonksiyonu
$\mathbb{H}$	Geçiş Fonksiyonu
SSR	Kalıntıların Kareleri Toplamı
W_g	LSTM Aday Kapısı Ağırlıkları
R_g	LSTM Aday Kapısı Sapmaları
W_o	LSTM Çıkış Kapısı Ağırlıkları
R_o	LSTM Çıkış Kapısı Sapmaları
W_i	LSTM Girdi Kapısı Ağırlıkları
R_i	LSTM Girdi Kapısı Sapmaları
W_f	LSTM Unut Kapısı Ağırlıkları
R_f	LSTM Unut Kapısı Sapmaları
C	Maliyet Fonksiyonu
F	Optimal Bölümlendirme Denklemi
f_t	t Anında LSTM unut kapısı
i_t	t Anında LSTM girdi kapısı
g_t	t Anında LSTM aday kapısı
o_t	t Anında LSTM çıktı kapısı
$\rho_{x,y}$	x ve y Arasındaki Korelasyon Katsayısı
tw	Zaman Penceresi

Kısaltmalar	Açıklama
AT-RUL	Anomali Tetiklemeli RUL
NASA	Amerikan Ulusal Havacılık ve Uzay Dairesi
BNN	Bayes Sinirsel Ağı
PELT	Budanmış Tam Doğrusal Zaman
BiGRU	Çift Yönlü Geçitli Tekrarlayan Birimler
MMoE	Çok Kapılı Uzmanlar Karışımı
MLP	Çok Katmanlı Algılayıcı
MS-DCNN	Çok Ölçekli Derin Evrişimli Sinir Ağı
DCNN	Derin Evrişimli Sinir Ağı
DLSTM	Derin Uzun Kısa Vadeli Bellek
DNN	Derin Sinirsel Ağ
SVR	Destek Vektör Regresyonu
LDA	Doğrusal Diskriminant Analizi
ReLU	Düzeltilmiş Doğrusal Ünite
LASSO	En Az Mutlak Büzülme ve Seçim Operatörü
RMSE	En Küçük Kök Ortalama Kare
LT	Etiketli Zaman Adımı

CNN	Evrişimli Sinir Ağı
GRU	Geçitli Tekrarlayan Birimler
GMDH	Grup Veri İşleme Yöntemi
2D	İki Boyutlu
BiLSTM	İki Yönlü Uzun Kısa Dönemli Bellek
ISOMAP	İzometrik Haritalama
RUL	Kalan Faydalı Ömür
RGB	Kırmızı, Yeşil, Mavi
CUMSUM	Kümülatif Toplam Kontrol Çizelgesi
k-NN	K-En Yakın Komşu
IoT	Nesnelerin İnterneti
MSE	Ortalama Karesel Hata
AE	Oto Kodlayıcı
PwL	Parçalı-Doğrusal
pwlf	Parçalı Doğrusal Fonksiyonlar
PHM	Prognostik ve Sağlık Yönetimi
RF	Rastgele Ormanlar
HI	Sağlık Endeksi
HS	Sağlık Durumu
PHT	Sağlık Zaman Adımı
EEMD	Tam Topluluk Ampirik Mod Ayrıştırması
1D	Tek Boyutlu
1-FCLCNN	Tek Boyutlu Tam Bağlı Katmanlı Evrişimli Sinir Ağı
PCA	Temel Bileşen Analizi
C-MAPSS	Ticari Modüler Hava Tahrik Sistemi Simülasyonu
ADAM	Uyarlanabilir Moment Tahmini
LSTM	Uzun Kısa Vadeli Bellek
3D	Üç Boyutlu
VMD	Varyasyonel Mod Ayrıştırması
ESN	Yankı Durum Ağı
LLE	Yerel Doğrusal Gömü
RNN	Yinelemeli Sinir Ağları
TCN	Zamansal Evrişimli Ağ

ŞEKİLLER DİZİNİ

		Sayfa
Şekil 1.1.	Bakım yönetimi sınıflandırması	2
Şekil 1.2.	Akıllı kestirimci bakım	4
Şekil 2.1.	RUL tahmin yöntemlerinin sınıflandırılması	9
Şekil 3.1.	C-MAPSS turbo fan motor şeması	19
Şekil 3.2.	Standart CNN modeli	22
Şekil 3.3.	Adım büyüklüğü "1" olan evrişim operasyonu	23
Şekil 3.4.	Maksimum havuzlama	25
Şekil 3.5.	1D-CNN için evrişim modeli	26
Şekil 3.6.	Temel RNN	27
Şekil 3.7.	LSTM hücresi	28
Şekil 3.8.	Oto kodlayıcı ağ yapısı	29
Şekil 3.9.	Önerilen prognostik prosedür	37
Şekil 3.10.	Temel CNN	40
Şekil 3.11.	Temel LSTM Sinirsel Ağı	40
Şekil 3.12.	Önerilen 1D-CNN- LSTM Sinirsel Ağı	41
Şekil 3.13.	RMSE ve skor fonksiyonu karşılaştırması	42
Şekil 4.1.	FD001 eğitim veri setindeki 100 motora ait sensör değerleri	44
Şekil 4.2.	FD001 eğitim veri setindeki #1 numaralı motora ait 14 adet sensörün ölçeklendirilmiş değerleri	45
Şekil 4.3.	Filtreleme (a) filtreleme öncesi ve (b) filtreleme sonrası	46
Şekil 4.4.	Öznitelik çıkarımı (a) eğitim veri setine ait 100 motor (b) test veri Setine ait 100 motor	48
Şekil 4.5.	Kayan zaman penceresi	49
Şekil 4.6.	Doğru sayısı parametresini değştirerek FD001'den rasgele seçilen Bir motorun değişim noktası tespit süreci (a) 2 doğru (b) 3 doğru (c) 4 doğru (d) 5 doğru	51
Şekil 4.7.	Eğitim veri setindeki tüm motorlara özgü RUL etiketleri	51
Şekil 4.8.	Eğitim veri setindeki tüm motorlar için RUL ile son ve ilk veri noktaları farkı arasındaki ilişki	53
Şekil 4.9.	5-katlı çapraz doğrulama	55
Şekil 4.10.	Hiper parametrelere ilişkin deneysel analiz sonuçları (a) katman sayısı (b) epok/dönem sayısı	57
Şekil 4.11.	Rastgele seçilen bir motorun eğitim sonuçları (a) 1D-CNN (b) LSTM (c) 1D- CNN-LSTM	59
Şekil 4.12.	Test veri setindeki gerçek ve tahmin edilen RUL değerleri arasındaki fark	61
Şekil 4.13.	Test veri setindeki 100 adet motor için RUL tahminleri (artan RUL'a göre sıralanmıştır) (a) fark özniteliği yok (b) fark özniteliği var	63

ÇİZELGELER DİZİNİ

		Sayfa
Çizelge 3.1.	C-MAPSS veri seti detayları.....	20
Çizelge 3.2.	C-MAPSS turbo fan motor sensör verilerinin tanımı.....	20
Çizelge 4.1.	FD001 veri setindeki sensör verilerinin trendi.....	45
Çizelge 4.2.	Oto kodlayıcı ağında değerlendirilen hiper parametre değerleri	47
Çizelge 4.3.	RUL tahmini için kullanılan sinirsel ağ hiper parametre değer aralıkları.....	55
Çizelge 4.4.	Seçilen hiper parametre değerleri.....	57
Çizelge 4.5.	Test veri seti üzerinde fark temelli özniteliğin kullanıldığı ve kullanılmadığı sinirsel ağlarda RUL tahmin performanslarının karşılaştırılması.....	60
Çizelge 4.6.	Derin öğrenme yöntemlerinde MAPE karşılaştırması.....	61
Çizelge 4.7.	Değişim noktası tespit yöntemlerinin karşılaştırılması.....	62
Çizelge 4.8.	Önerilen yöntem ile C-MAPSS veri setini içeren ilgili makalelerin performans karşılaştırması.....	64

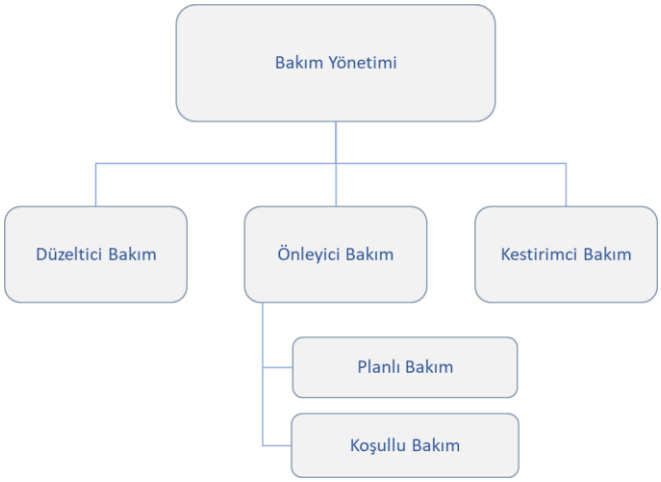
1. GİRİŞ

Sanayi Devrimleri, tarihin belirli dönemlerinde gerçekleşen teknolojik, ekonomik ve endüstriyel değişimlerin önemli birer yansımasıdır. Son sanayi devrimi olarak da nitelendirilen endüstri 4.0 kavramı, bilgi ve teknolojik gelişmelerin desteğiyle, üretim süreçlerinde önemli dönüşümlere neden olmuştur. Bu dönüşümün, üretim ortamlarındaki fiziksel ve dijital sistemlerin entegrasyonu ile güçlü bir ilişkisi vardır. Endüstri 4.0 ile gelen yeni teknolojiler; insanları, makineleri ve ürünleri entegre ederek daha hızlı ve hedef odaklı bilgi alışverişine olanak sağlar.

Endüstri 4.0'ın sağladığı entegrasyon, farklı sektörlerdeki farklı fabrikalardan, farklı ekipmanlardan büyük miktarda veriler toplanmasına olanak sağlar (Borgi ve diğerleri, 2017). Endüstriyel sistemlerden elde edilen büyük miktardaki veriler endüstriyel üretim hatlarındaki süreçler, olaylar ve olağan dışı durumlar hakkında bilgi içerirler. Veriler analiz edildiğinde, üretim süreçleri ve içinde bulunduğu sistem dinamikleri ile ilgili değerli bilgiler ortaya çıkarır. Verilere dayalı analitik yaklaşımlar uygulayarak, stratejik karar verme için yorumlanabilir sonuçlar bulmak, üretim miktarı ve etkinliğini arttırmak, yedek parça stoklarını azaltmak, bakım maliyetlerini düşürmek, makine arızasını azaltmak, onarım duruşlarını azaltmak, operatör güvenliğini sağlamak ve genel kârı arttırmak gibi avantajlar sağlamak mümkündür.

Veriye dayalı analitik yaklaşımların sağladığı avantajların endüstriyel ekipmanların bakım süreçleriyle güçlü bir ilişkisi vardır. Bakım faaliyetleri etkin bir şekilde yapılmadığı takdirde hem ilgili parçanın hem de etkileşim içerisinde olduğu diğer kritik parçaların ve dolayısıyla makine ile içerisinde bulunduğu sistemin arızalanmasına neden olacaktır. Bu durumda, kalitesizlik, işçilik, bakım onarım ve duraklamadan kaynaklanan çeşitli maliyetlerin oluşması söz konusu olacaktır. Bu nedenle ekipman arızalarının, üretim sürecinin durdurulmadan belirlenmesi ve çözülmesi gerekmektedir.

Zamanla gelişen bilgi ve teknolojinin etkisiyle bakım faaliyetleri de dönüşüme uğramıştır. Literatürde farklı isimlendirmeler ve sınıflandırmalar bulunmakla birlikte genel olarak bakım yönetimi düzeltici bakım, önleyici bakım ve kestirimci bakım olarak gruplandırılmıştır (Susto ve diğerleri, 2015) ve Şekil 1.1'de gösterilmiştir.



Şekil 1.1. Bakım yönetimi sınıflandırması

Düzeltici bakım, arıza meydana geldikten sonra gerçekleştirilen bakım türüdür (Susto ve diğerleri, 2012). Bakım stratejilerinin erken dönem uygulaması olarak nitelendirilmektedir. Yatırım maliyetlerinin düşük olduğu, onarımın kısa sürede gerçekleşebildiği ve arızaların günlük operasyonlar için çok kritik olmayan ekipmanlarda gerçekleştiği küçük işletmeler için avantajlı bir yaklaşımdır (Martin, 1994). Ancak, uzun süreli duruşlara sebep olması, iş gücü maliyetinin yüksek olması ve yüksek stok gerekliliğine ihtiyaç duyması dezavantajlarıdır.

Önleyici bakım, beklenmedik arızaların önlenmesini amaçlayan bir bakım stratejisidir. En yaygın türü planlı bakım faaliyetleridir. Arızaları önlemek amacıyla sistemin periyodik olarak gözden geçirilmesine dayanır. Düzeltici bakımın aksine, bu bakım genellikle üretim zamanı dışında uygulanır. Bu tür bir bakımın amacı, periyodik kontroller ve aşınmış parçaların değiştirilmesi yoluyla uygulanan düzeltici bakım eylemlerinin sayısını azaltmaktır (Jimenez-Cortadi ve diğerleri, 2020). Planlı bakımda kritik olan, ideal bakım aralığının belirlenmesidir. Arızaların gerçekleşme olasılığını değiştirmemekle birlikte gereğinden fazla yapılan bakım faaliyetleri maliyetlerin artışına sebep olabilmektedir.

Makine arızalarının %99' unda, arıza gerçekleşmeden önce spesifik olmayan bir gösterge ile belirti verdiği ortaya konmuştur (Geitner ve Bloch, 2012). Bu bilgi ışığında, planlı bakımın getirdiği gereksiz bakım yükünü azaltmaya yarayan, sistemin ve ekipmanların normal işleyişini kesintiye uğratmadan, ilgili göstergelerdeki değişiklikleri sürekli izleme

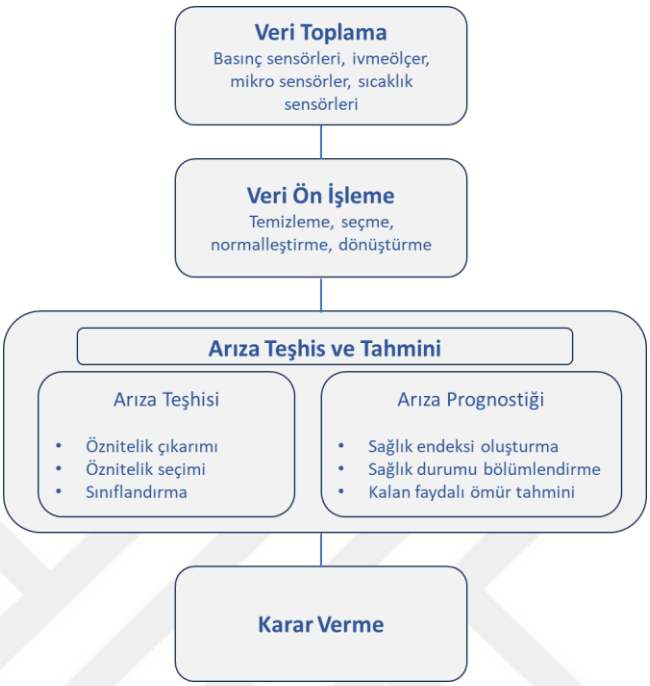
yoluyla takip eden ve arıza gerçekleşmeden hemen önce bakım yapılmasına olanak sağlayan koşullu bakım stratejisi geliştirilmiştir (Borgi ve diğerleri, 2017). Bu bakım stratejisinde sistemin veya ekipmanın fiziksel durumu, çeşitli sensörlerden periyodik veya sürekli olarak gelen veriler ile izlenir. Yalnızca sistem veya ekipmanın durumunda bir anormallik tespit edildiği zaman bakım faaliyetlerinin gerçekleştirilmesini sağlar. Koşullu bakım gereksiz bakım faaliyetlerini azaltmada yardımcı olsa da bakım planının önceden yapılamaması en büyük dezavantajıdır (Susto ve diğerleri, 2012).

Düzeltici bakım stratejisini uygulamayı tercih eden endüstriler, bakım eylemlerini geciktirir ve yedek parçaların elde bulundurmama riskini üstlenir. Sadece arıza sayısının az veya emniyet riskinin bulunmadığı, kritik olmayan durumlarda uygundur. Öte yandan, önleyici bakım, bakım müdahalelerini öngörür ve yedek parça değişimini gerçekleştirir. Bu nedenlerle, iyi bir bakım stratejisi; ekipmanın durumunu iyileştirmeli, ekipman arıza oranlarını azaltmalı ve bakım maliyetlerini en aza indirirken ekipmanın kullanım ömrünü en üst düzeye çıkarmalıdır. Ancak bu faaliyetler de beklenmedik anda gerçekleşen arızaların önüne geçmede yetersiz kalmaktadır.

Gün geçtikçe karmaşıklaşan, takibi zorlaşan üretim süreçlerine paralel olarak gelişen sensör ve yazılım teknolojileri; düzeltici ve önleyici bakım türünün yetersiz kaldığı arızaların gerçekleşme zamanını belirlemeye olanak sağlayan kestirimci bakım stratejisini ortaya çıkarmıştır. Kestirimci bakımda ekipmanlar ve makineler üzerindeki sensörler yardımıyla sistemin mevcut durumun değerlendirilmesini sağlamasının yanı sıra elde edilen büyük boyutlardaki verinin çeşitli tahmin araçları kullanılarak analiziyle olası arızaların önceden tahmin edilmesine olanak sağlar (Susto ve diğerleri, 2012, 2015). Kestirimci bakımda ana fikir, mevcut durumun izlenerek gelecek yansımasını oluşturmak ve arıza gerçekleşme zamanını belirlemeye çalışmaktır (Gouriveau ve diğerleri, 2016). Kestirimci bakım yalnızca beklenmedik arızaların sayısını ve buna bağlı maliyetleri azaltmakla kalmaz, aynı zamanda bakım planını optimize eder ve güvenilir bir çalışma ortamı sağlar.

Endüstri 4.0, makineler, ürünler, hizmetler, ekipmanlar ve araçlar arasında bilgi teknolojisi tabanlı iletişim ve etkileşim sağlayarak akıllı ve esnek üretim kontrolünü kolaylaştırmaktadır. Akıllı sistemler ve bunlardan elde edilen büyük veri çağında akıllı

bir kestirimci bakım sistemi temel olarak; veri toplama ve ön işleme, arıza teşhisi, arıza prognostiği ve karar vermeyi içeren dört bölümden oluşur (Xu ve diğerleri, 2019).



Şekil 1.2. Akıllı kestirimci bakım

Prognostik ve Sağlık Yönetimi (PHM), kestirimci bakımı durum izleme ve veri toplama, arıza teşhisi, prognostik ve veri analizini içeren bir mühendislik süreci olarak tanımlayan genel bir terimdir (İnce, 2023). Nesnelerin İnterneti (IoT) teknolojisinin ilerlemesiyle birlikte, endüstriyel büyük veri olarak da bilinen çeşitli veri türleri ekipman üzerindeki çeşitli sensörlerden elde edilir ve analiz edilmek üzere depolanır (Lee ve diğerleri, 2014). Bu veriler genellikle titreşim sinyali, basınç sinyali, akım sinyali gibi durum izleme verileri ile sıcaklık, nem gibi çevresel bilgi verilerini ve arıza, bakım, onarım gibi tarihsel kayıt verilerini içermektedir. Elde edilen ham veriler genellikle eksik, tutarsız, gürültülü ve anormal değerler içerdiğinden doğrudan analiz için uygun olmamaktadır. Veri kalitesi, analiz ile elde edilen sonuçlar üzerinde büyük önem taşımaktadır. Bu nedenle ham veriden doğru bilgiyi edinebilmek için ön işlemler gerçekleştirilir (Xu ve diğerleri, 2019).

Arıza teşhisi ve prognostik, kestirimci bakımın iki yaygın uygulamasıdır. Teşhis, arıza tespiti olarak bilinir ve bir sistemde veya cihazda meydana gelen arızaları veya sorunları tanımlama ve analiz etme sürecini ifade eder. Bu süreç, sistemin davranışı veya

performansında meydana gelen sapmaların veya anormalliklerin türünü, lokasyonunu, derecesini mümkün olduğunca erken belirleme ve ardından bu sorunların temel nedenlerini ortaya çıkarma işlemini içerir (Liu ve diğerleri, 2020). Mekanik sistemlerden elektrik sistemlerine kadar çeşitli alanlara uygulanabilen arıza teşhisi, arızaları erken tespit ederek bakım ekiplerinin zamanında önlem almasını sağlamayı amaçlar.

Prognostik, bir sistemin veya bileşenin mevcut durumuna ve geçmiş verilerine dayanarak kalan faydalı ömrünü (RUL) tahmin etme sürecidir. RUL, bir varlığın mevcut çalışma süresi ile ömrünün sonuna işaret eden çalışma süresi arasındaki ölçülen fark olarak tanımlanır (Si ve diğerleri, 2011). Durum izleme verilerini kullanarak izlenen bir sistemin RUL'unu tahmin etmek özel bir araştırma alanıdır, çünkü durum ölçümleri ile RUL tahmini arasında açık ve bilinen genel bir ilişki yoktur (Ragab ve diğerleri, 2017).

Teşhis ve prognostik, birbirlerinden bağımsız uygulanabileceği gibi birbirine paralel ve seri olacak şekilde de uygulanabilmektedir. Analizler sonucu elde edilen bilgiler, bakım süreçleriyle ilgili karar vermede destek olurlar. Bu proaktif yaklaşımlar, beklenmedik duraksamaların önüne geçmekle kalmaz, aynı zamanda ekipmanın daha fazla zarar görmesini engeller, genel sistem güvenilirliğini artırır ve nihayetinde iş süreksizliklerini azaltarak operasyonel verimliliği arttırırlar.

Sensör ve iletişim teknolojilerinin hızla gelişmesiyle birlikte, giderek daha fazla sayıda gelişmiş veri toplama cihazı tasarlanmış ve modern endüstrilere uygulanmıştır. Ancak, makineler genellikle sağlıklı çalışır durumundan arızaya kadar uzun vadeli bir bozulma süreci geçirirler ve bu süreç birkaç ay hatta yıllar sürebilir. Bu tür uzun vadeli bir bozulma süreci sırasında tüm çalışmadan arızaya kadar olan verileri yakalamak zaman alıcı ve pahalıdır. Pratikte, makinelerin arızaya kadar çalışmasına izin verilmez çünkü beklenmedik bir arıza tüm makinenin bozulmasına ve kazalara yol açabilir. Bu gibi durumlarda, endüstriyel alanlarda arızaya kadar çalışma verilerinin elde edilmesi zordur (Lei ve diğerleri, 2018).

Rüzgâr türbini dişli kutuları, otomotiv dişli kutuları ve uçak motorları gibi makineler zorlu çevre koşullarında çalışır. Dış ortamdan gelen çok sayıda parazit/gürültü izleme verilerine karışır, böylece verilerin kalitesi düşer. Duruş süresi veya yeniden başlatma süresi gibi birçok izleme verisi hizmet dışı dönemde yakalanır. Bu ölçümler genellikle

hizmet içi dönemde elde edilen ölçümlere kıyasla farklı davranışlar sergiler ve böylece izleme verilerinin kalitesini düşürür.

Arızadan arızaya veri toplayabilen az sayıda askeri veya ticari kurum, askeri sır veya ticari rekabet nedeniyle verilerini yayınlamak istemektedir. Bu nedenlerle, çoğu prognostik veri kümesi, gerçek endüstriyel ekipman yerine her zaman özel hazırlanmış bozulma test düzeneklerinden elde edilmektedir (Lei ve diğerleri, 2018). Prognostik yaklaşımların geliştirilmesini kolaylaştırmak için, Amerika Birleşik Devletleri'nin uzay programı çalışmalarından sorumlu olan Ulusal Havacılık ve Uzay Dairesi'ne (NASA) bağlı Prognostik Mükemmeliyet Merkezi, prognostik yaklaşımların gösterilmesi için özel olarak oluşturulmuş çok sayıda veri kümesini toplayan bir prognostik veri havuzu (NASA Prognostics Center of Excellence) kurmuştur.

Kestirimci bakım, kazaların insan hayatı ve ekonomik kayıplar açısından potansiyel olarak yıkıcı etkisi nedeniyle güvenilirliğin çok önemli olduğu havacılık gibi sektörlerde kritik bir rol oynamaktadır. Tez çalışması kapsamında gerçekleştirilecek kestirimci bakımın alt dalı olan prognostik yaklaşım için NASA Prognostik Mükemmeliyet Merkezi'nin sağladığı turbo fan motorlara ait üretilen veriler üzerinde çalışılmıştır, çünkü turbo fan motor bir uçağın en kritik bileşenidir. Yüksek güvenilirlik ve kalite gerektiren en karmaşık bileşenlerden biridir. RUL tahmini, turbo fan motorların maliyet unsurlarını azaltmaya ve güvenilirlik unsurlarını arttırmaya yönelik bakım stratejileri geliştirmek için gereklidir (Wang ve diğerleri, 2022).

Bu tez çalışması, turbo fan motorlarında RUL tahmini için yenilikçi bir yaklaşım sunarak literatüre önemli katkılar sağlamaktadır. Literatürde RUL etiketlemesine ilişkin geçerli kesin bir ilişki bulunmadığından, tahmin sonuçlarının genelleştirilebilmesi amacıyla benimsenen, literatürde yaygın olarak kullanılan ve tüm motorlar için aynı olduğu varsayılan maksimum RUL değeriyle yapılan etiketlemenin aksine, motorların bozulma süreçlerini gerçek hayat problemine yaklaştıracak şekilde her bir motora özgü RUL etiketlemesi üzerine odaklanmıştır.

Motora özgü RUL etiketlemesinde, turbo fan motorlarda olası bir geç RUL tahmininin sebep olacağı maddi ve manevi olumsuz durumlardan kaçınmak için mümkün olduğunca sensör sinyallerindeki bozulma göstergesinin yerinin doğru tahmin edilmesi

hedeflenmiştir. Sensör sinyallerindeki bozulma değişiminin ilk başladığı noktayı belirleyebilmek için kullanılan parçalı-doğrusal fonksiyonlar üzerinde elde edilmesi istenen doğru sayısı parametresi değiştirilerek, mevcut sensör sinyallerinde motorun bozulmasını temsil eden en erken değişim noktası belirlenmeye çalışılmıştır.

Genelleştirmeyi sağlayan maksimum RUL değerinin tüm motorlar için aynı olduğu varsayılan RUL etiketleme yönteminin aksine, motora özgü RUL etiketlemesi benimseyen bu tez çalışmasında, gerçek hayat problemine yakınlaşan turbo fan motorları RUL tahmin problemi, motorların sağlıklı çalıştığı erken dönemde RUL tahminin zorlaşmasına neden olmuştur. Zorlaşan RUL tahmin probleminin, tahmin doğruluğun arttırabilmek ve motorların erken dönem bozulma süreçlerini daha iyi temsil etmesini sağlamak için öznitelik mühendisliği yaklaşımlarından faydalanılmıştır. Mevcut veri setindeki özniteliklerden, motorların erken dönem bozulma süreçlerini daha iyi temsil edecek yeni öznitelik oluşturulmuştur.

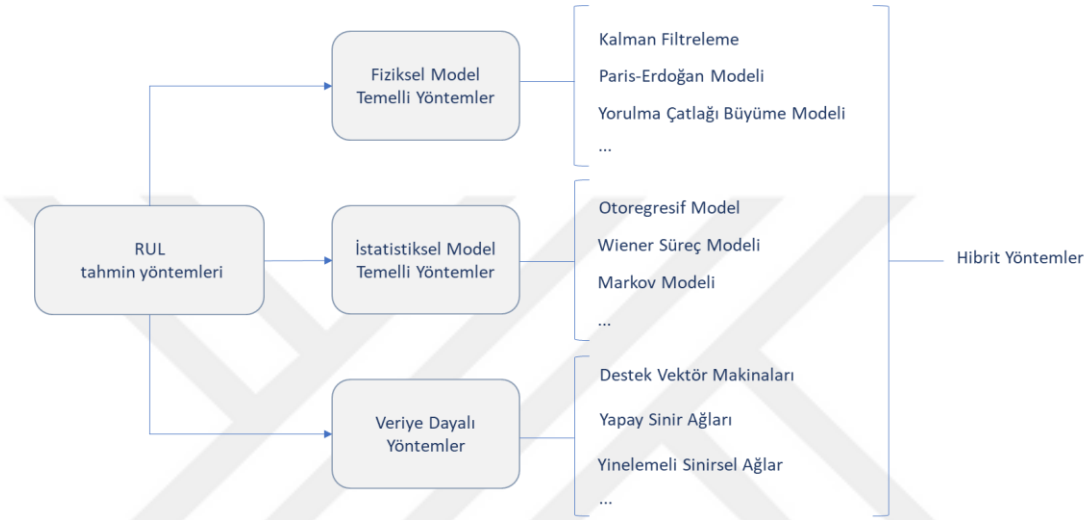
Bu tez çalışması, turbo fan motorlarında RUL tahminine odaklanarak veri odaklı bir yaklaşım sunmaktadır. Özellikle, esnek bir hedef etiketleme yaklaşımı ile öznitelik mühendisliği stratejilerini birleştiren ve hibrit derin öğrenme tekniklerinden yaralanan özgün bir metodoloji ile literatürde benzerine rastlanmayan bir yaklaşım sergilemektedir. Problemin esnek hedef etiketleme yaklaşımıyla gerçek hayat problemine yaklaştırılması hedeflenmiştir. Gerçek hayat problemine yaklaşan turbo fan motorlarına ait RUL tahmin problemine ilişkin değerlendirmede, benzer çalışmaların aksine orijinal test verileri kullanılmıştır ve bu alandaki önceki çalışmalardan ayrı bir perspektif sunarak, endüstriyel uygulamalarda RUL tahmininde etkili ve özelleştirilmiş stratejiler geliştirmeye yönelik önemli bir katkı sunmaktadır.

Bu tez çalışmasının ikinci bölümünde, turbo fan motorlarında RUL tahminine yönelik bugüne kadar yapılmış çalışmalar ve bunların katkıları ile mevcut tez çalışmasının literatür içerisindeki yeri ve katkıları detaylı şekilde açıklanmıştır. Bölüm 3.1'de deneysel çalışmanın gerçekleştirildiği C-MAPSS veri setinin FD001 alt veri seti hakkında detaylı bilgilendirme yapılmıştır. Bölüm 3.2'de tez çalışması kapsamında kullanılan derin öğrenme yöntemleri, öznitelik mühendisliği yaklaşımları, oto kodlayıcılar, değişim noktası tespiti yöntemlerinin teorik alt yapısı açıklanmış ve önerilen prognostik prosedür

ile RUL tahmininde kullanılan sinirsel ağ mimarisi hakkında bilgi verilmiştir. Bununla birlikte, önerilen metodolojinin performansını gösteren değerlendirme kriterleri açıklanmıştır. Bölüm 4.1'de veri ön işleme adımları, hedef etiketleme yaklaşımı, öznitelik mühendisliği yöntemleri ile önerilen sinirsel ağlara ilişkin hiper parametre ayarlarının gerçekleştirilmesine ilişkin uygulamalar deneysel çalışma kapsamında açıklanmıştır. Elde edilen sonuçlar Bölüm 4'te farklı sinir ağı mimarilerinin tahmin performansları önerilen mimari ile karşılaştırılmış, hedef etiketleme yaklaşımının performansı değerlendirilmiş ve öznitelik mühendisliğinin önerilen sinirsel ağ modeli üzerindeki katkısı gösterilmiştir. Bununla birlikte tez çalışmasında elde edilen sonuçlar benzer yöntemlerinin kullanıldığı çalışmalarla karşılaştırılmıştır. Son olarak, Bölüm 5'te çalışmanın sonuçları değerlendirilmiş ve gelecek çalışmalar hakkında önerilerde bulunulmuştur.

2. KAYNAK ÖZETLERİ

Literatürde turbo fan motorlar üzerinde gerçekleştirilmiş çok sayıda çalışma mevcuttur. Turbo fan motorlar üzerinde gerçekleştirilen RUL tahmin çalışmaları genel olarak Şekil 2.1'de gösterildiği gibi; temel olarak fiziksel model tabanlı, istatistiksel model tabanlı ve veri odaklı olacak şekilde sınıflandırılmıştır (Khelif ve diğerleri, 2017; Li ve diğerleri, 2018).



Şekil 2.1. RUL tahmin yöntemlerinin sınıflandırılması

Fiziksel bir modele dayanan yöntemler, sistemin davranışını temsil eden ve değişimi deterministik bir yasa veya stokastik bir süreçle modellenen bozulma mekanizmasını entegre eden dinamik bir modelin oluşturulmasını gerektirir. Mühendislik ve bilimsel yaklaşımlarla oluşturulmuş bir dizi matematiksel denklemin çözümüyle ekipman ve bileşenlerin sağlığını değerlendirirler (Sikorska ve diğerleri, 2011). Paris-Erdoğan modeli ile bozulma mekanizması modellenerek ve RUL tahmini yapan çalışmalar fiziksel model tabanlı çalışmalara örnektir (Lei ve diğerleri, 2016; Liao, 2014). Fiziksel model tabanlı yöntemler daha kesin sonuçlar verme ve yorumlanabilir olma özelliklerine sahiptir. Ancak, model parametreleri sistemin büyüklüğü ve karmaşıklığıyla yakından ilgilidir. Fiziksel model tabanlı yöntemlerin zorluğu, alan bilgisi ve uzmanlık gerektirmesinin yanı sıra, günümüz sitemlerinin artan karmaşıklığı nedeniyle bozulma mekanizmalarını analitik bir biçimde bütünleştiren dinamik bir model elde edememek ve başka bir fiziksel sisteme aktarılmasının güçlüğüdür (Gouriveau ve diğerleri, 2016).

İstatistiksel model tabanlı yöntemler, RUL'u olasılıksal olarak tahmin etmek için çeşitli varsayımlara sahip modeller kullanırlar. Wiener süreci (Le Son ve diğerleri, 2013) ve gamma süreci (Le Son ve diğerleri, 2016) gibi istatistiksel teknikler bozulma modellemesi için kullanılırken, Markov tabanlı modeller (Giantomassi ve diğerleri, 2012) turbo fan motorlar için bir RUL tahmin modeli olarak kullanılmıştır. Ancak, gerçek hayat sistemlerinin karmaşıklığı nedeniyle elde edilen veriler istatistiksel modellerin varsayımlarına ilişkin koşulları çoğunlukla karşılayamamaktadır. Bu nedenle ilgili süreçlerin yönetiminde kullanılacak modellerin geçerliliği ve sistemin güvenilirliği sağlanamamaktadır.

Veri odaklı yaklaşımlar, geçmiş sensör verilerini faydalı bilgilere dönüştürerek sistem bozulmasının özelliklerini ortaya çıkarabilir. Gelişmiş sensör ve bilgisayar teknolojileri ile veri odaklı yaklaşımlar, endüstri ve akademide daha az uzmanlıkla karmaşık sistem bozulmaları hakkında bilgi edinmek için yaygın olarak kullanılmaktadır. Hibrit yaklaşımlar, model tabanlı ve veri odaklı yaklaşımların avantajlarından yararlanmak için yukarıda bahsedilen iki yaklaşımın birlikte kullanıldığı yöntemlerdir. Ancak hibrit yaklaşımların da her iki yöntemden kaynaklanan kısıtlamaları vardır ve bu durum hibrit yaklaşımların kullanımını zorlaştırmaktadır. Bu tez çalışmasına ait literatür araştırmasında, turbo fan motorların RUL tahmininde veri odaklı yaklaşımlara geniş yer verilmiştir.

Veri odaklı yaklaşımlar veri analizi tekniklerine ve yapay zekaya dayanmaktadır (Huang ve diğerleri, 2019). Yapay zekâ, başta derin öğrenme teknikleri olmak üzere makine öğrenmesi yöntemlerini kullanır (Yu ve diğerleri, 2019). Denetimli öğrenme için sinyal verilerinin bozulma sürecini gösteren hedef değerlere ihtiyacı vardır. Literatürde turbo fan motorlara ilişkin bir bozulma modeli oluşturmak için parçalı doğrusal (PwL) fonksiyon hedef değer olarak kullanılmaktadır (Heimes, 2008). Bu model, RUL'un belirli bir arıza noktasına kadar sabit olduğunu varsayar. Bu arıza noktasından sonra doğrusal olarak azalır. Genelleştirmeyi sağlamak ve RUL tahmin problemlerinin karmaşıklığını azaltmak için, tüm motorlar motorların normal/sağlıklı çalışması sırasında aynı sabit RUL hedef değerini kullanır (Li ve diğerleri, 2018; Song ve diğerleri, 2018; Zhao ve diğerleri, 2020).

Derin öğrenme tabanlı RUL tahmin yöntemleri turbo fan motorlar için önemli sonuçlar üretmiştir. Turbo fan motorlar üzerine yapılan birkaç çalışmada, zaman serisi verilerini analiz etmek için yinelemeli sinir ağları (RNN) gibi derin öğrenme teknikleri kullanılmıştır. Zaman serisi verileri için bir derin öğrenme tekniği olan RNN, kısa vadeli bağımlılıkları başarılı bir şekilde elde edebilir ancak uzun vadeli bağımlılıkları öğrenmede sorun yaşar. Bir uzun kısa vadeli bellek (LSTM) ağı, uzun süreli bağımlılık sorununun üstesinden gelmek için zamana bağlı bilgi akışını kapılar aracılığıyla kontrol eder.

Zheng ve diğerleri (2017) sensörlerden gelen zaman dizisi verilerini kullanarak RUL tahminleri yapmak için bir LSTM ağ modeli önermiştir. Bu ağ modeli ile gizli Markov ve geleneksel RNN modellerine kıyasla daha iyi RUL tahmin doğruluğu elde etmişlerdir. Wang ve diğerleri (2019) RUL tahmini için çift yönlü uzun kısa vadeli bellek (BiLSTM) ağı ile sensör veri dizisini kullanmış ve BiLSTM ağının geleneksel makine öğrenimi yaklaşımlarından daha iyi performans gösterdiğini belirtmiştir. Wu ve diğerleri (2020), çalışmalarında çoklu sensör zaman serisi sinyallerini kullanarak derin uzun kısa vadeli bellek (DLSTM) ağı tabanlı bir ömrünü tahmin etme yöntemi önermektedir. DLSTM modeli, derin öğrenme yapısı aracılığıyla sensör zaman serisi sinyalleri arasındaki gizli uzun vadeli bağımlılıkları keşfetme yeteneği sayesinde doğru RUL tahmini için çoklu sensör sinyallerini birleştirmiştir. Ağ arama stratejisi kullanılarak DLSTM'nin ağ yapısı ve parametreleri etkili bir şekilde ayarlanarak doğru ve güvenilir bir tahmin sağlamıştır. İki farklı turbo fan motoru veri seti, DLSTM modelinin performansını doğrulamak için kullanılmış ve önerilen modelin rekabetçi bir performansa sahip olduğu belirtilmiştir. Song ve diğerleri (2018), büyük örneklem boyutu ve izleme verilerinin yüksek boyut özelliklerini göz önüne alarak, RUL'un tahmin doğruluğunu artırmak için oto kodlayıcı (AE) ve BiLSTM'in avantajlarını birleştiren hibrit bir sağlık durumu tahmin modeli önerilmiştir. Oto kodlayıcı, durum izleme verilerini birleştirmek için bir öznitelik çıkarıcı olarak, BiLSTM ise özniteliklerin çift yönlü uzun vadeli bağımlılıklarını yakalamak için kullanılmıştır. AE-BiLSTM hibrit modelinin çok katmanlı algılayıcı (MLP), destek vektör regresyonu (SVR), evrişimli sinir ağı (CNN) ve LSTM gibi mevcut yöntemlerden daha iyi bir tahmin doğruluğuna sahip olduğunu belirtmişlerdir. Peng ve diğerleri (2022), karmaşık ve gürültülü ortamlarda makinelerin RUL'un tahmin edilmesindeki zorlukları

ele almak için çift kanallı bir LSTM sinir ağı modeli önermiştir. Yöntem, zamansal özniteliklerini uyarlamalı olarak seçmekte, birinci dereceden işleme gerçekleştirmekte ve ilgili bilgileri çıkarmak için LSTM kullanmaktadır. Tahmin edilen RUL eğrisindeki zikzak desenini yumuşatarak tahmin doğruluğunu artırmak için bir momentum yumuşatma modülü eklenmiştir. Ticari Modüler Hava Tahrik Sistemi Simülasyonu (C-MAPSS) veri kümesi üzerinde yapılan deneysel doğrulama, yöntemin etkinliğini ve kararlılığını göstermektedir. Wang ve Zhao (2022) LSTM sinir ağı ile RUL tahmini için çok ölçekli bir yaklaşım sunmuştur. Öznitelik çıkarımı için Pearson korelasyon katsayısı kullanılmıştır. Bozulma sürecini bozulma olmayan, geçiş ve doğrusal bozulma aşamaları olarak üç bölüme ayıran RUL hedef fonksiyonu önermiştir. Küçük ölçekli RUL tahmini, bu aşamaların LSTM tabanlı bir ikili sınıflandırma algoritması ve bir korelasyon yöntemi kullanılarak sınıflandırılmasını içerir. Son iki aşama için özel bir LSTM tabanlı tahmin modeli geliştirilerek büyük ölçekli bir RUL tahmini elde etmiştir.

Derin öğrenme yöntemlerinden bir diğeri olan CNN, öznitelik çıkarma konusundaki üstünlüğü nedeniyle turbo fan RUL tahmininde yaygın olarak kullanılmaktadır. Li ve diğerleri (2018), derin evrişimli sinir ağları (DCNN) kullanarak prognostik için veri odaklı bir yaklaşım önermektedir. DCNN tarafından daha iyi öznitelik çıkarımı için örnek hazırlamada zaman penceresi yaklaşımı kullanılmıştır. Normalleştirme ile toplanan ham verilerin doğrudan önerilen ağa girdi olarak kullanılması ve prognostik ve sinyal işleme konusunda önceden uzmanlık gerektirmemesi nedeniyle uygulanması kolay olarak belirtilmiştir. Muneer ve diğerleri (2021) çalışmalarında mekanik sistemlerin doğrusal olmama ve yüksek derecedeki karmaşıklığına dikkat çekerek geleneksel yöntemlerin sınırlılığını ele almış ve öznitelik sıralaması ve seçimi için bir öngörülebilirlik metriği ve örnek hazırlama için bir zaman penceresi yöntemi kullanarak, turbo fan motorlarının RUL tahmininde dikkat tabanlı DCNN modeli aracılığıyla öznitelik çıkarımını geliştirerek tahmin performansı üzerindeki zamansal bilgilerin ihmalini azaltmaya çalışmışlardır. Chen ve diğerleri (2021), zaman serilerindeki uzamsal ve zamansal verilerden etkin bir şekilde yararlanabilmek ve bunu yaparken zamansal öznitelikli modellerin yavaşlığından kaçınmak için zamansal evrişimli ağ (TCN) kullanmışlardır. Kullanılan filtreler ile alıcı alan büyütülerek daha geniş zaman penceresindeki öznitelikler dikkate alınabilmiştir. Tan ve Teo (2021) çalışmalarında, prognostik için dikkat mekanizmasına sahip hafif bir CNN

uygulayan bir yaklaşım önermektedir. Evrişimli filtreler çoklu zaman serilerinden soyut zamansal örüntüleri çıkarmak için, dikkat mekanizmaları ise zaman eksenindeki bilgileri gözden geçirip, ilgili bilgileri seçmek için kullanılmıştır. Li ve diğerleri (2020) RUL tahmini için çok ölçekli derin evrişimli sinir ağı (MS-DCNN) önermiştir. MS-DCNN için, üç çok ölçekli blok kullanmışlardır. Farklı boyutlardaki paralel evrişim işlemleri, öznitelik çıkarma sürecini güçlendirmiştir. Algoritma, veri ön işleme, model eğitimi ve RUL tahmini olmak üzere üç aşamadan oluşmaktadır ve NASA'nın C-MAPSS veri setinde değerlendirme yapılmıştır ve önerilen modelin hesaplama yükünü azalttığı belirtilmiştir. Peng ve diğerlerinin (2022) önerdiği model, verinin zamansal ilişkilerini ve uzamsal durumlarını kapsamlı bir şekilde ele almaktadır. Zamansal ilişkileri temsil etmek için tekrarlayan sinir ağlarına ihtiyaç duymadan pozisyon kodlaması ile CNN kullanılmıştır. C-MAPSS veri setleri üzerinde yapılan deneysel sonuçların, zamansal ve uzamsal boyutları entegre ederek tahmin performansında önemli bir iyileşme gösterdiği belirtilmiştir.

Literatürde, tahmin modellerinin genelleştirme yeteneğini artırmak ve sensör ölçümlerinin zamansal ve uzamsal özniteliklerini birlikte düşünmek amacıyla çeşitli tipte CNN ve RNN modelleri hibrit bir şekilde kullanılmıştır. Al-Dulaimi ve diğerleri (2019), LSTM ve CNN derin öğrenme modelini aynı anda ve paralel bir şekilde entegre ederek, çeşitli prognostik senaryolarda genelleme performansını artırmayı amaçlayan bir hibrit derin öğrenme sinir ağı modeli önermişlerdir. Önerilen modelin, NASA C-MAPSS veri kümesinin, çeşitli operasyon koşulları ve hata modları içeren karmaşık prognostik senaryolarında üstün performans sergilediği belirtilmiştir. Zhao ve diğerleri (2020), CNN modellerinin zamansal özniteliklerle ilgili eksikliklerini, LSTM modellerinin ise uzamsal özniteliklerle ilgili eksiliklerini giderebilmek için bu iki modelin güçlü yanlarını birleştirmeye yarayan hibrit bir tahmin modeli önermişlerdir. Literatürdeki en başarılı uygulamalara kıyasla daha iyi performans gösterdiğini belirtmişlerdir. Wang ve Wu (2021) verinin çok boyutlu ve gürültülü oluşuna dikkat çekerek AE, CNN ve BiLSTM ağlarından oluşan ve ACB adını verdikleri bir model oluşturmuşlardır. Önerilen hibrit model ile veri boyutu ve gürültünün azaltılmasının yanı sıra kayıp fonksiyonuna özel bir ceza puanı ekleyerek abartılı tahmin sonuçları elde etmenin önüne geçmeye çalışmışlardır. Peng ve diğerleri (2021), tahmin doğruluğunu arttırmak için tek öznitelik

çıkarımı yapmak yerine hem zamansal hem de uzamsal özniteliklerin çıkarımı için tam evrişim katmanlı tek boyutlu evrişimli sinir ağlarını (1-FCLCNN) ve LSTM ağından oluşan hibrit bir ağ kullanmışlardır.

Derin öğrenmenin kullanıldığı bir grup çalışmada dikkat mekanizması kullanılmıştır. Dikkat mekanizması, girdi olarak kullanılan zaman serilerinin ilgili kısımlarına seçici bir şekilde odaklanmak için kullanılmakta, değişken uzunluktaki dizilerin işlenmesini kolaylaştırmakta ve bağlamsal bilgiyi yakalamada fayda sağlamaktadır. Liu ve diğerleri (2021), dikkat tabanlı yaklaşımın önerdikleri bu makalede, çift yönlü geçitli tekrarlayan birimler (BiGRU) ve CNN kullanılarak geliştirilen yöntem ile eğitim sırasında kritik özniteliklere dinamik olarak vurgu yaparak turbo fan motorları üzerinde RUL tahmini yapmışlardır. Gong ve diğerleri (2022) çalışmalarında RUL'u hassas bir şekilde tahmin etmek için birden fazla sensörden gelen zaman serisi verilerini etkili bir şekilde birleştiren, dikkat mekanizmasına dayalı bir TCN-BiGRU modeli önermişlerdir. Model, gürültü sinyallerini bastırmak için varyasyonel mod ayrıştırması (VMD) ve hiper parametreleri optimize etmek için ızgara araması ve k-katlı çapraz doğrulamadan yaralanmıştır. C-MAPSS turbo fan motoru ve sızdırmazlık halkası veri kümeleriyle yapılan deneylerde diğer modellere kıyasla üstün RUL tahmin doğruluğu gösterdiği belirtilmiştir.

Derin öğrenmeyle turbo fan motorlarında yapılan çalışmaların diğer bir grubunda ise, motorların bozulma süreçleriyle ilgili mevcut verilerden daha fazla bilgi elde edinip öğrenmeyi sağlamak ve dolayısıyla tahmin doğruluğunu arttırmak için yeni özniteliklerin oluşturulması üzerinde durulmuştur. Peng ve diğerleri (2022) ile Wu ve diğerleri (2018), turbo fan motorları gibi karmaşık fiziksel sistemlerdeki gizli desenleri ortaya çıkarabilmek için derin mimarilere ve dolayısıyla daha fazla eğitim verisine sahip olmak gerektiğini ancak diğer bir seçeneğin ise ham veri kümelerinden yeni öznitelikler elde etmek olduğunu öne sürmüşlerdir. Xiao ve diğerleri (2021) kullandıkları LSTM ağına kasıtlı olarak gürültü eklemenin yanı sıra motorlardaki bozulmayı gösteren korelasyon analizi temelli yeni öznitelikler oluşturarak C-MAPSS turbo fan motorlarında geçerliliğini test etmişlerdir. Chen ve diğerleri (2021) mekanik sistemlerde RUL tahmininde geleneksel LSTM ağlarının öğrenilmiş öznitelikleri etkili bir şekilde kullanma konusundaki sınırlamalarını vurgulamaktadır. Önerilen LSTM ağı ve dikkat

mekanizması yardımıyla, manuel olarak oluşturulmuş öznitelikler ve otomatik olarak öğrenilen öznitelikleri birleştirerek RUL tahmininde üstün performans sergilemiştir. Zhao ve diğerleri (2019) RUL tahmini için, bozulmanın genel zaman dizisinden türetilen trend özniteliklerine odaklanan yeni bir yaklaşım sunmaktadır. Önerilen yöntem, tam topluluk ampirik mod ayrıştırması (EEMD) ve koşullu sinirsel süreçleri kullanarak trend özelliklerini değerlendirmekte ve RUL tahmini için veri odaklı bir LSTM ağ modeli geliştirilmiştir. C-MAPSS veri kümesi üzerinde yapılan deneysel doğrulama, RUL tahmininde en küçük kök ortalama kare (RMSE) değerleriyle yöntemin etkinliğini ortaya koymaktadır. Bae ve Xi (2022) prognostik ve sağlık yönetiminde gelişmiş algoritmaların yanı sıra veri kalitesinin önemini vurgulamışlardır. Önerdikleri yaklaşım, bir test ünitesindeki etiketli zaman adımının (LT) yerine daha bilgilendirici bir alternatif olarak fiziksel sağlık zaman adımını (PHT) öğrenmek LSTM ağının kullanılmasını içermektedir. Çalışma veya gözlem endekslerini kaydeden LT'nin aksine PHT, ünitenin fiziksel sağlığını mevcut duyusal ölçümlerden tahmin etmekte ve ünitenin geçmiş değerlerini dikkate alarak RUL tahmini yapmaktadır.

Bahsedilen çalışmalarda hedef RUL etiketlemesi için azalan bir PwL fonksiyonu kullanılmıştır. Literatürde parçalı RUL'un maksimum değer alan ve sabit olan kısmındaki değeri RUL_{max} olarak belirtilir. RUL_{max}, veri setindeki tüm motorlar için ortak bir değer olarak belirlenmiştir. Bu yaklaşım, problemin ve ona ilişkin modellerin genellenebilirliği açısından faydalıdır ancak turbo fan motorların gerçek dünyadaki durumunu yansıtmamaktadır. Her bir motorun bozulma süreci diğerinden farklıdır. Motora özgü PwL hedef etiketlemesi üzerine yapılan çalışmalar, tüm motorlar için ortak bir RUL_{max} kullanan çalışmalara göre daha azdır. Bunun temel nedeni, motorun sağlıklı durumundaki RUL'u tahmin ederken motorları birbirinden ayırmak için yeterli verinin olmamasıdır. Ayrıca, test veri setinde sensör verilerinin belirli bir noktada kesilmiş olması, hedef RUL'a ilişkin PwL fonksiyonu için değişim noktasının kesin olarak belirlenmesini engellemektedir. Motora özgü RUL_{max} kullanan çalışmaların büyük bir kısmı yalnızca eğitim veri kümesi üzerinde model geliştirmiş ve yine eğitim veri kümesi üzerinde modellerinin geçerliliğini test etmiştir. Miao ve diğerleri (2019), operasyonel güvenilirliği, iş güvenliği arttırmak ve bakım maliyetlerini azaltmak için hem motorların bozulma değerlendirmesini hem de RUL tahminini eş zamanlı yapan çift amaç

fonksiyonlu bir LSTM ağı önermiştir. Önerilen yöntem, RUL hedef etiket fonksiyonlarını ve sağlık durumuna bağlı etiketleri dinamik olarak oluşturarak uyarlanabilirlik sağlar. Farklı LSTM hücre yapılarının karşılaştırmalı analizine de yer verilmiştir. Zhang ve diğerleri (2022) endüstriyel ekipmanların sağlık durumunu (HS) eş zamanlı olarak değerlendirmek ve RUL tahminini eş zamanlı olarak gerçekleştirmek için BiGRU ve çok kapılı uzmanlar karışımından (MMoE) yararlanan çift görevli bir ağ yapısı sunmaktadır. BiGRU, her iki görev için sensör sinyallerinden çift yönlü olarak paylaşılan bilgileri çıkarırken, MMoE yapısı sağlık durumu (HS) değerlendirmesi ve RUL tahmini arasında uyarlanabilir farklılaşmayı kolaylaştırarak ağırlıklı karar vermeyi geliştirmiştir. Ek olarak, homoskedastik belirsizlik tabanlı bir kayıp fonksiyonu, RUL tahmini ve HS değerlendirmesi arasındaki ağırlık öğrenimini otomatikleştirerek manuel ağırlık ayarlama ihtiyacını ortadan kaldırmıştır. Chehade ve Shi (2021), önceki çalışmalarda kullanılan sabit değişim noktası yaklaşımını gevşeterek belirsiz olan değişim noktalarının tespiti için ve RUL tahmini için iki aşamalı LSTM ağı önermiştir. İlk aşamada değişim noktaları tespit edilmiş, sonrasında motorların sağlık durumunu gösteren tek boyutlu parçalı azalan bir sağlık endeksi (HI) oluşturulmuş ve RUL tahmini yapılmıştır.

Her bir motor için farklı RUL_{max} değeri hesaplayan değişim noktası tespiti çalışmaların bir bölümünde, motorların sağlıklı çalıştığı dönemde bozulma sürecini belirgin şekilde gösteren bilginin yetersizliği sebebiyle RUL tahmini, değişim noktasından sonraki çevrim zamanlarında tespit edilmiştir. Baptista ve diğerleri (2021) gelişmiş prognostik ve RUL tahmini için sistemlerin bozulma eğrisindeki değişim noktasını "dirsek noktası" olarak adlandırmış ve tespit etmenin önemini vurgulamışlardır. Dirsek noktası tespiti için standart RNN, LSTM ve geçitli tekrarlayan birimler (GRU) dahil olmak üzere RNN'ler kullanılmış ve GRU'nun üstün performans gösterdiği belirtilmiştir. En iyi performans gösteren GRU dedektörünün bir yankı durumu ağı (ESN) ile entegrasyonu, genel RUL tahmin performansını önemli ölçüde arttırdığı vurgulanmıştır. Aydemir ve Acar (2020) çalışmalarında makinelerin sağlıklı çalışması sırasında RUL tahmin etme zorluğunu ele alarak bir anomali izleme yaklaşımı sunmuşlardır. RUL tahmincisinin eğitimi ve uygulaması sırasında anomali tespiti kullana Anomali Tetiklemeli RUL (AT-RUL) prosedürünün RUL tahmin doğruluğunu arttırdığını belirtmişlerdir. Önerilen yaklaşım, değişmeyen çalışma koşullarında gösterilen bir örnekte, basit bir anormallik tespit

mekanizmasını lineer regresör, rastgele ormanlar (RF) ve derin LSTM ağları gibi popüler RUL tahmini modelleri ile entegre etmektedir. Kümülatif Toplam (CUSUM) kontrol grafiği anormallikleri etkili bir şekilde tespit ederek hem yerinde simülasyonlarda hem de C-MAPSS turbo fan motor bozulma verilerinde hesaplama maliyetini azaltarak RUL tahmini doğruluğunu arttırmıştır.

Turbo fan motorlar için RUL tahmini alanında yapılan çalışmalar göz önüne alındığında, hedef etiketleme yaklaşımları, özellik mühendisliği süreçleri ve etkili ağ modellerinin geliştirilmesi alanlarında kapsamlı ve öncü araştırmalara ihtiyaç olduğu ortaya çıkmaktadır.

Bu tez çalışmasında öncelikle turbo fan motorlarda RUL tahmini için veri odaklı yaklaşımlar, özellikle de derin öğrenme teknikleri çalışılmıştır. LSTM ve CNN dahil olmak üzere çeşitli derin öğrenme yöntemleri incelenmiş ve RUL tahmini için değişim noktası tespitine dayalı hedef etiketleme ve öznitelik mühendisliği yöntemlerini birleştiren yeni bir yaklaşım önerilmiştir. Motor yaşam ömrünün farklı aşamalarında RUL tahmininin doğruluğunu artırmayı amaçlanmış ve motor davranışının daha gerçekçi bir temsili için motora özgü RUL etiketlerini kullanılmıştır. Bu tez çalışmasında C-MAPSS turbo fan verileri kullanılarak kapsamlı bir deneysel çalışma sunulmuş ve sonuçlar önerilen yöntemin etkinliğini göstermek için literatürdeki kapsamı benzer yöntemlerle karşılaştırılmıştır.

Birçok açıdan özgün değer taşıyan tez çalışmasının literatüre ana katkıları aşağıdaki gibidir:

i. Bildiğimiz kadarıyla bu çalışma, RUL tahmininde değişim noktası tespitine dayalı hedef etiketleme ve özellik oluşturmayı birleştiren ilk çalışmadır.

ii. RUL tahmin çalışmalarındaki mevcut eğilime uygun olarak; esnek bir hedef etiketleme yaklaşımı benimsenmiş, yenilikçi öznitelik mühendisliği stratejileri kullanılmış ve karşılaştırmalarla doğrulandığı üzere hesaplama karmaşıklığını en aza indirirken tahmin doğruluğunu arttırmayı hedefleyen verimli bir hibrit ağ sunulmuştur.

iii. Literatürdeki çalışmaların çoğunda RUL tahmini için 120, 125 ve 130 gibi sabit bir RUL_{max} değerine sahip PwL hedef etiketleri kullanılmıştır. Ancak bu çalışmada her motor için motora özgü bir PwL hedef etiketi kullanılmış ve problem gerçekçi bir zemine oturtulmaya çalışılmıştır.

iv. Önceki çalışmalar, orijinal eğitim veri setini iki ayrı kümeye bölerek hem eğitim hem de test için kullanmıştır. Onlardan farklı olarak, bu çalışma adil bir değerlendirme sağlamak için orijinal test veri kümesini kullanarak RUL tahminine odaklanmıştır.

v. Motora özgü hedef RUL için oto kodlayıcı tabanlı bir öznitelik çıkarma yöntemi kullanılarak birleştirilen tek boyutlu verilerin etiketlenmesi için sürekli PwL fonksiyonları oluşturulmuştur. Bilinmeyen değişim noktalarının diferansiyel evrim tabanlı optimizasyon algoritması ile belirlendiği Python kütüphanesi pwlf (piece-wise linear functions) kullanılmıştır. İlk değişim noktasını bulmada önemli bir gelişme sağlanamayana kadar artan sayıda doğru segmenti kullanılmıştır. Parçalı hedef RUL etiketlemesi için en erken ilk değişim noktası seçilmiştir.

vi. Her döngüdeki sensör ölçümleri ile ilk sensör ölçümü arasındaki farkı içeren manuel bir öznitelik oluşturulmuş ve veri kümesine yeni bir öznitelik olarak eklenmiştir. Böylece, orta ve erken yaşam evrelerinde RUL tahmini iyileştirilmiştir.

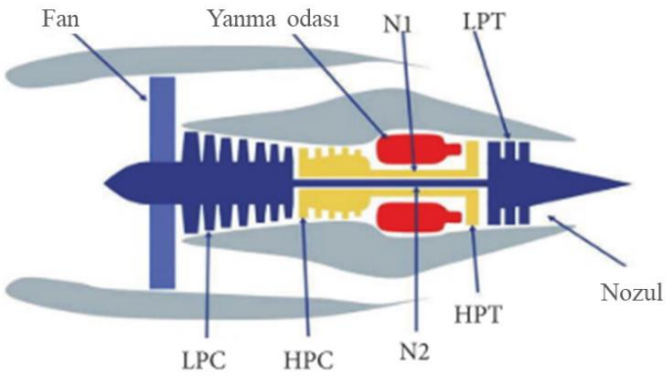
3. MATERYAL ve YÖNTEM

Tez çalışması kapsamında gerçekleştirilecek prognostik yaklaşım için NASA Prognostik Mükemmeliyet Merkezi'nin sağladığı turbo fan motorlara ait üretilen veriler üzerinde çalışılmıştır. Bölüm 3.1'de kullanılan veri seti hakkında bilgi verilmiştir. Bölüm 3.2'de, önerilen prognostik prosedürün gerçekleştirilmesi için kullanılan yöntemlere ve bu yöntemlere ilişkin akış şemasına yer verilmiştir.

3.1. Materyal

Bu tez çalışmasında, turbo fan motorlarının RUL tahmini için önerilen yaklaşım, NASA'nın turbo fan motorları bozulma veri seti üzerinde uygulanmış ve değerlendirilmiştir. NASA'nın C-MAPSS veri seti olarak da adlandırılan turbo fan motorlara ait veri seti, NASA'nın özel sistem seviyesi model tabanlı simülasyon programı yazılımı kullanılarak oluşturulan ve yaygın olarak kullanılan bir kıyaslama verisidir.

C-MAPSS, büyük bir ticari turbo fan motorda bulunan ve Şekil 3.1'de şematik olarak gösterilen; fan, alçak basınç kompresörü, yüksek basınç kompresörü, yüksek basınç türbini ve alçak basınç türbini olmak üzere ana döner bileşendeki farklı çalışma koşullarında arızaların ve bozulmaların etkilerini simüle eden bir yazılımdır.



Şekil 3.1. C-MAPSS turbo fan motor şeması

C-MAPSS veri seti, FD001, FD002, FD003 ve FD004 olmak üzere dört farklı alt küme içeren simüle edilmiş bir veri setidir. Farklı veri setlerine genel bir bakış Çizelge 3.1'de verilmiştir.

Çizelge 3.1. C-MAPSS veri seti detayları

	FD001	**FD002**	**FD003**	**FD004**
Eğitim birimleri	100	260	100	249
Test Birimleri	100	259	100	248
Çalışma Koşulları	1	6	1	6
Hata Türleri	1	1	2	2

Her bir veri seti; eğitim birimleri, test birimleri, çalışma koşullarının sayısı ve hata türleri açısından farklıdır. Eğitim birimleri, belirli bir başlangıç koşulundan arızaya kadar olan farklı motor ömrü sürelerinin miktarını temsil eder. Test birimleri, model doğruluğunu değerlendirmek için uygulanabilecek farklı bir motor setidir. İki hata türü, yüksek basınçlı kompresör (HPC) bozulması ve turbo fan bozulmasıdır. FD001 ve FD002 için sadece HPC bozulması mevcutken, FD003 ve FD004 için her iki arıza türü da mevcuttur. FD001 ve FD003 yalnızca tek bir çalışma koşuluna ilişkin veri sağlamaktadır; bu koşul deniz seviyesidir. FD002 ve FD004 altı farklı koşulda çalışmaktadır.

Her set $Nx26$'lık bir matris içerir. Burada N mevcut veri noktalarının sayısıdır. İlk sütun ilgili motorun kimliğini ve ikinci sütun operasyonel çevrim değerini temsil eder. Sonraki üç sütun motorun operasyonel ayarlarıdır. Son 21 sütun ise motor tarafından sağlanan farklı sensörlere ait ölçümleridir ve gürültü ile kontamine edilmiştir. İlgili sensör tanımları Çizelge 3.2'de gösterilmiştir.

Çizelge 3.2. C-MAPSS turbo fan motor sensör verilerinin tanımı

Sensör No.	**Sensör Tanımı**	**Birim**
1	Fan giriş sıcaklığı	°R
2	LPC çıkış sıcaklığı	°R
3	HPC çıkış sıcaklığı	°R
4	LPT çıkış sıcaklığı	°R
5	Fan giriş basıncı	psia
6	bypass-kanal basıncı	psia
7	HPC çıkış basıncı	psia
8	Fiziksel fan hızı	rpm
9	Fiziksel çekirdek hızı	rpm
10	Motor basınç oranı P50/P2	-
11	HPC çıkış statik basıncı	psia
12	Yakıt akışının Ps30'a oranı	pps/psia
13	Düzeltilmiş fan hızı	rpm
14	Düzeltilmiş çekirdek hızı	rpm

Çizelge 3.2. C-MAPSS turbo fan motor sensör verilerinin tanımı (devam)

15	Bypass oranı	-
16	Brülör yakıt-hava oranı	-
17	Hava Alma Entalpisi	J
18	Gerekli fan hızı	rpm
19	Gerekli fan dönüştü	rpm
20	Yüksek basınçlı türbinler soğuk hava akışı	lb/s
21	Düşük basınçlı türbinler soğuk hava akışı	lb/s

Veri setindeki karmaşıklık FD001'den FD004'e doğru artmaktadır. FD002, FD003 ve FD004 veri setleri arıza türleri ve çalışma koşullarındaki farklılıkları da doğal olarak içinde barındırdığından, tez çalışması kapsamında, hedef etiketlemeyle gerçek hayat problemine benzetilerek zorlaşan RUL tahminine yönelik önerilen prognostik prosedürün geçerliliğini test etmek ve etkinliğini değerlendirmek için çalışma koşulları ve arıza türlerindeki farklılıkları içermeyen FD001 alt veri seti seçilmiştir. FD001 alt veri seti eğitim ve test veri setlerini içermektedir. Eğitim setinde, her çalışma çevriminde periyodik olarak toplanan 21 sensör değerinin zaman serisi, motorların tüm kullanım ömrünü kapsar. Aksine, test setinde, motor sensörü okumaları sistem arızalanmadan önce rastgele bir çalışma çevriminde sonlandırılır. FD001 alt veri kümesinde eğitim veri kümesi için 20.631 ve test veri kümesi için 13.096 çevrim sayısı bulunmaktadır. Test veri kümesindeki son çevrim noktası RUL'un tahmin edileceği noktadır. RUL tahmininin birincil amacı, eğitim veri kümesine dayalı bir model oluşturmak ve önerilen modeli kullanarak test veri kümesindeki son nokta için RUL tahmini yapmaktır.

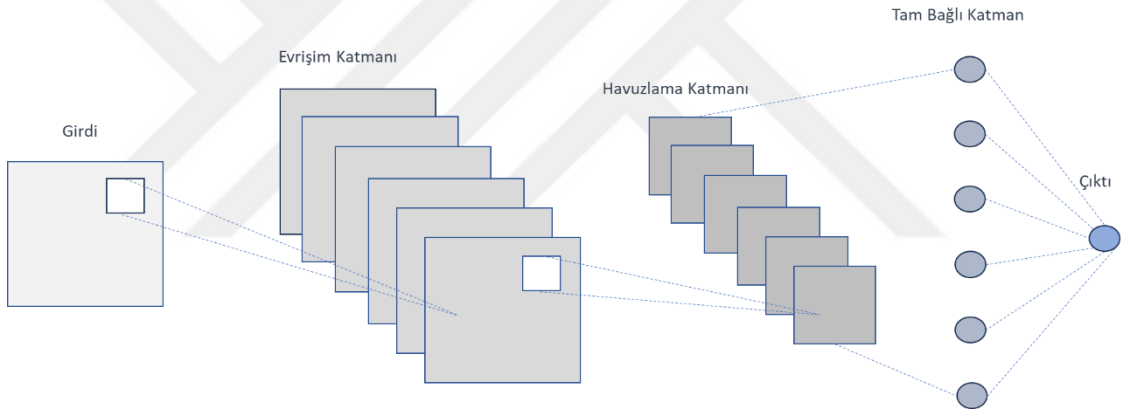
3.2. Yöntem

İlk olarak, RUL tahmininde kullanılacak derin öğrenme tekniklerinden CNN ve LSTM sinirsel ağları tanımlanmıştır. Ardından, öznitelik mühendisliği sürecinde kullanılan teknikler ve yine sürecin öznitelik çıkarımı aşamasında kullanılan oto kodlayıcıların kavramsal çerçevesi açıklanmaktadır. Her bir motora özgü RUL etiketlemesi için kullanılan değişim noktası tespit yöntemlerine yer verilmiştir. Son olarak bu teknikler yardımıyla oluşturulan ve önerilen prognostik prosedür detaylıca açıklanmış ve tahmin için kullanılan sinirsel ağ modelleri hakkında bilgilendirme yapılmıştır.

3.2.1 Evrişimli sinir ağları (CNN)

CNN nesneleri tanımlayabilen, tanıyabilen ve sınıflandırabilen çok katmanlı sinir ağlarına dayalı yapay zekâ sistemidir. CNN ilk olarak LeCun ve diğerleri (2015) tarafından önerilmiştir. CNN tekniği bilgisayarla görme, doğal dil işleme ve konuşma tanıma gibi farklı alanlarda kullanılmış ve önemli başarılar elde etmiştir. Kullanılan birçok verinin biçimi çoklu diziler şeklindedir: Sinyaller ve diziler için tek-boyutlu (1D); görüntüler veya ses spektrogramları için iki-boyutlu (2D) ve video veya hacimsel görüntüler için üç-boyutlu (3D).

Standart bir CNN temel olarak üç katmandan oluşmaktadır: Evrişim katmanı, havuzlama katmanı ve tam bağlı katman (Li ve diğerleri, 2019). Standart bir CNN modeli Şekil 3.2'de gösterilmiştir.



Şekil 3.2. Standart CNN modeli

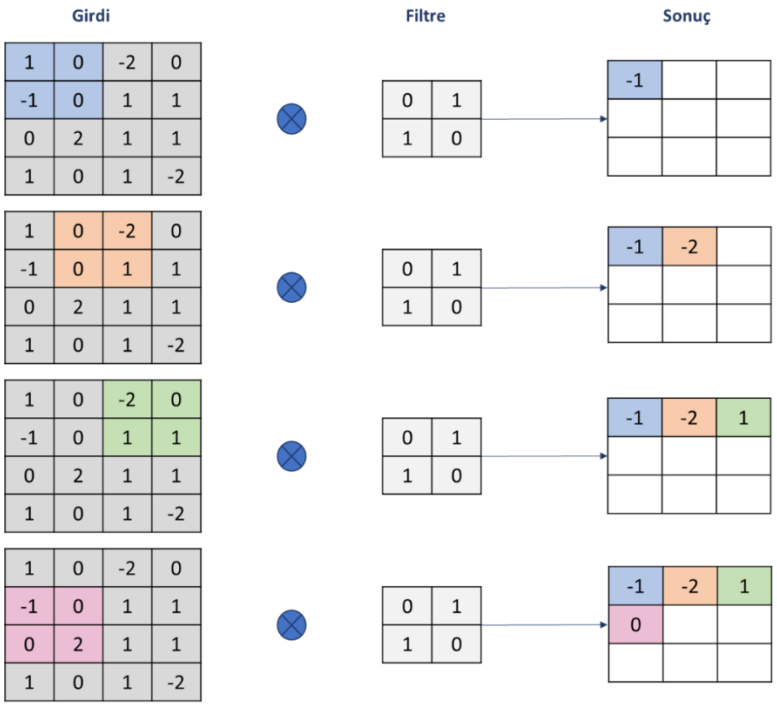
Evrişim katmanı, bir CNN modelinin en kritik katmanıdır. Hesaplamalar ağırlıklı olarak bu katmanda yapılmaktadır. Bu katman, ağırlık değerlerini de içeren filtre veya kernel olarak adlandırılan bir dizi matris içerir. Farklı filtreler, farklı ağırlıklar sahiptir. Evrişim işlemi, filtreyi giriş verileri üzerinde kaydırır ve her adımda filtre ağırlıkları ile giriş verileri arasındaki iç çarpımı hesaplar. Bu filtre ve girdinin birleştirilmesi sonucunda bir öznitelik haritası üretilir. Filtreler genişlik, yükseklik ve ağırlıklarıyla yalnızca girdi katmanı için değil, bir önceki katmanda oluşturulan bir öznitelik haritası üzerinden de çeşitli karakteristikleri içeren yeni öznitelik haritası çıkarılmasında kullanılır. Farklı filtreler, farklı öznitelik haritaları oluşturur. Filtrelerin başlangıç ağırlıklarını belirlemede

farklı yaklaşımlar bulunsa da ilk değerleri rassal olarak oluşturulur ve eğitim sırasında güncellenirler. İç çarpım sonucu elde edilen öznitelik haritası, düzeltilmiş doğrusal ünite (ReLU) veya Sigmoid gibi aktivasyon fonksiyonları ile karmaşık ve doğrusal olmayan ilişkileri ortaya çıkarabilecek özellik kazanırlar. Evrişim operasyonu Denklem 3.1 ile tanımlanır;

$$x_{k'}^{L} = \varphi\left(\sum_{k \in M} w_{kk'} * x_{k}^{L-1} + b_{k'}^{L}\right) \tag{3.1}$$

x_k^{L-1} , $L-1$ katmanındaki k öznitelik haritasının çıktısını, $w_{kk'}$, $L-1$ katmanı k öznitelik haritasından, L katmanı k' öznitelik haritasına olan filtreyi, $*$ evrişim operasyonunu, $b_{k'}^{L}$, L katmanı k' öznitelik haritası sistematik sapmasını (bias), φ doğrusal olmayan aktivasyon fonksiyonunu, $x_{k'}^{L}$, L katmanındaki k' öznitelik haritasını ve M ise girdideki öznitelik sayısını temsil etmektedir.

Evrişim operasyonu sırasında filtreler, girdinin boyutları doğrultusunda hareket ederler. Filtrenin; önceden belirlenmiş hareket birimi kadar kaydırılması, adım (stride) olarak adlandırılmaktadır. Adım büyüklüğü 1 olacak şekilde örnek bir evrişim operasyonu Şekil 3.3'te gösterilmiştir.



Şekil 3.3. Adım büyüklüğü "1" olan evrişim operasyonu

Adım değerini artırmanın bir faydası, sonuçta ortaya çıkan öznitelik haritasının boyutluluğunda bir azalma gerçekleştirmesidir. Evrişim operasyonu sırasında girdi boyutu ve adım büyüklüğü dikkate alınarak elde edilecek çıktı büyüklüğü her bir boyut için Denklem 3.2 kullanılarak hesaplanır.

$$Çıktı\ boyutu = \frac{Girdi\ boyutu - Filtre\ boyutu}{Adım} + 1 \tag{3.2}$$

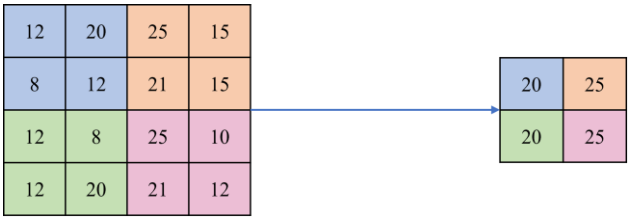
Girdi matrisi veya öznitelik haritalarına uygulanan filtreler bu matrislerin kenarlardaki değerlerini, merkezdeki değerlerinden sayıca daha fazla işler. Kenarlardaki verilerin daha az işlenmesi, girdi veya öznitelik haritalarının kenarlarından elde edilecek bilgide kayba neden olacaktır. Bununla birlikte eklenecek katmanlarla, uygulanacak filtreleme sonucunda veri boyutunda azalma meydana gelecektir. Bu küçülme, verinin geniş bağlamda değerlendirilmesini zorlaştırabilir ve ağın yüksek seviyeli soyut öznitelikleri öğrenme yeteneğini azaltabilir. Evrişim operasyonu sonrası girdi ve çıktı arasındaki boyut farkını düzenlemek için kenar dolgusu (padding) uygulanmaktadır. Temel olarak kenar dolgusuz (valid), aynı kenar dolgusu (same padding) ve tam kenar dolgusu (full padding) olmak üzere üç çeşit uygulaması vardır. Kenar dolgusunun kullanılmadığı durumda, ilgili katmanın girdi verisine herhangi bir dolgu yapılmaz ve kenardaki değerler daha az işlem görür. Aynı kenar dolgusu yaklaşımında, ilgi katmanın girdi ve çıktı boyutunun aynı kalmasını sağlamak adına, kenarlara aynı miktarda dolgu eklenir. Tam kenar dolgusunda ise, kenarlarda bilgi kaybı olmayacak şekilde yapılan dolgudur. Uygulamada genellikle yapılan dolguların değeri, dolgunun işlemler üzerindeki etkisini azaltmak ve ağırlıklı olarak gerçek veriyi temsil etmesini sağlamak için sıfır olarak kullanılır.

CNN'in temel katmanlarından bir diğeri havuzlama (pooling) veya aşağı örnekleme (down-sampling) katmanıdır ve evrişim katmanının hemen ardından yer alır. Temel görevi, en önemli verileri koruyarak öznitelik haritasının boyutunu ve hesaplama karmaşıklığını azaltmaktır. Boyutları önceden belirtilen bir bölge üzerinde işlem yapar ve ϕ havuzlama işlemini belirtmek üzere Denklem 3.3 ile tanımlanır;

$$x_k^L = \phi(x_k^{L-1}) \tag{3.3}$$

Uygulamalarda ortalama havuzlama kullanılsa da çoğunlukla maksimum havuzlama kullanılmaktadır. Maksimum havuzlama her bölge içinden en büyük değeri seçerek

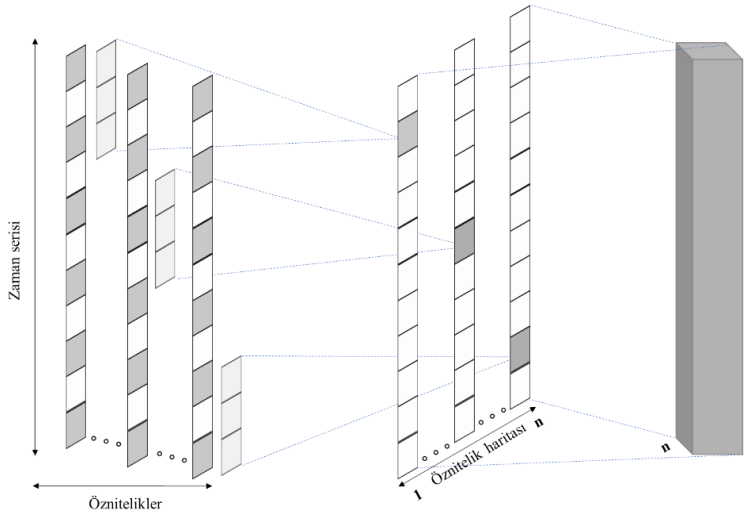
çalışırken, ortalama havuzlama bölge üzerindeki değerlerin ortalamasını alarak çalışır. Maksimum havuzlama örneği Şekil 3.4'te verilmiştir.



Şekil 3.4. Maksimum havuzlama

Evrişim ve havuzlama katmanlarını genellikle tam bağlı katmanlar takip eder. Tam bağlı katmanlar, bir katmandaki her bir nöronu bir önceki ve bir sonraki katmandaki her bir nörona bağlar ve çıkarılan öznitelikler üzerinde sınıflandırma veya regresyon gerçekleştirmek için kullanılırlar.

CNN yapısı çoğunlukla görüntü işleme için kullanılsa da farklı veri türlerine uygulanabilmektedir. CNN, kullanılan filtrenin girdi verisi üzerinde gezdiği boyutlarına göre 1D-CNN, 2D-CNN ve 3D-CNN olarak kullanılmaktadır. Zaman serileri, ses dalgaları ve metin verileri gibi tek boyutlu veriler üzerinde 1D-CNN mimarisi kullanılmaktadır. 1D-CNN'in girdi ve çıktısı $(zaman\ adımları \times öznitelik\ sayısı)$ olmak üzere iki boyutludur ve 1D-CNN'de filtre, zaman adımı boyunca tek boyutta kaydırılır (Ellefsen ve diğerleri, 2019). Şekil 3.'te yüksekliğin zaman adımlarını, genişliğin ise öznitelik sayısını temsil ettiği çok değişkenli bir zaman serisi için 1D evrişim operasyonu gösterilmiştir.



Şekil 3.5. 1D-CNN için evrişim modeli

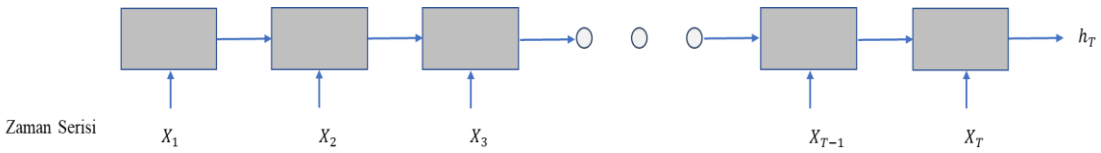
1D-CNN'leri kullanmanın ana avantajlarından biri, sıralı veriler içindeki belirli desenleri/kalıpları ve öznitelikleri yakalayabilmeleridir. Bu özelliği, zamana bağlı verilerdeki anormalliklerin tespiti gibi görevlerde yardımcı olabilmektedir. Ek olarak, 1D-CNN'ler diğer derin öğrenme modellerine göre daha az hesaplama kaynağı gerektirir ve bu da sınırlı kaynaklara sahip uygulamalarda yardımcı olmaktadır (Hong ve diğerleri, 2020; Lecun ve diğerleri, 2015).

2D-CNN'ler için girdi verisinin türü çoğunlukla görüntü verisidir. Girdi verisinin boyutları (yükseklik, genişlik, kanal sayısı) şeklindedir. Kanallar, her bir kanalın belirli bir renk bileşenini temsil ettiği renk kanallarını ifade eder ve çoğunlukla RGB (kırmızı, yeşil, mavi) olacak şekilde üç kanal içerir. Filtreler, yükseklik ve genişlik boyutlarınca kaydırılırlar. 3D-CNN'ler ise çoğunlukla video verileri ve medikal görüntüler üzerinde çalışır. Girdi verisi (yükseklik, genişlik, derinlik, kanal sayısı) olmak üzere dört boyutludur. 3D-CNN girdi verisindeki derinlik boyutu, her bir kare için bir 2D görüntüyü ve zaman boyunca bir dizi kareyi içermektedir. Filtreler ise yükseklik, genişlik ve derinlik boyutlarında kaydırılmaktadır.

3.2.2. Yinelemeli sinir ağları (RNN) ve uzun-kısa vadeli bellek (LSTM)

RNN'ler tüm sinir ağları arasında en derin olanıdır ve belirli uzunluktaki giriş örüntüleri dizilerinin belleklerini oluşturabilmekte ve işleyebilmektedir (Schmidhuber, 2015). RNN, yönlendirilmiş bir döngü aracılığıyla birimler arasında bağlantılar kurabilmektedir.

Sadece girdi verilerinden hedef vektörlere eşleme yapabilen MLP gibi temel sinir ağlarından farklı olarak RNN, önceki girdilerin tüm geçmişinden hedef vektörlere eşleme yapabilir ve ağın iç durumunda önceki girdilerin kaydının tutulmasını sağlar (Zhao ve diğerleri, 2019). RNN'ler, sıralı girdi verileri ve hedef çıktıları olan denetimli öğrenme için zaman içinde geri yayılım yoluyla eğitilebilmekte ve Şekil 3.6'da gösterildiği gibi dahili belleğini kullanarak sıralı verileri işlemektedir.



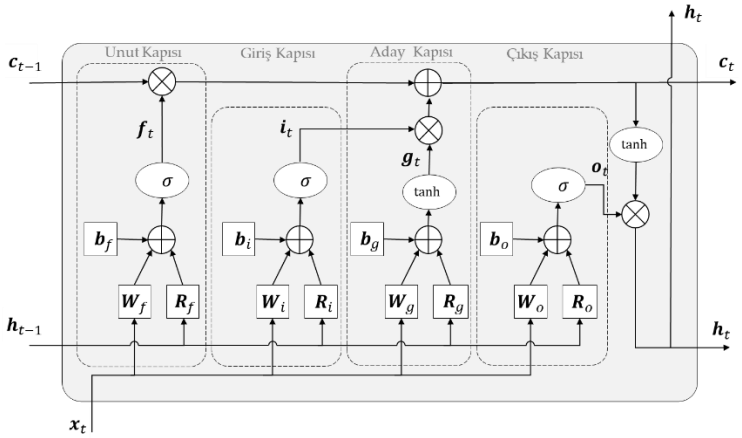
Şekil 3.6. Temel RNN

Her t anında tanımlanan doğrusal olmayan ve türevlenebilir $\mathbb{H}$ geçiş fonksiyonu, mevcut zaman bilgisi x_t ve önceki gizli çıktı h_{t-1}'i alır ve mevcut gizli çıktıyı Denklem 3.4 ile günceller.

$$h_t = \mathbb{H}(x_t, h_{t-1}) \tag{3.4}$$

Tüm dizi işlendikten sonra, son zaman adımındaki gizli çıktı olan h_T, uzunluğu T olan sıralı girdi verisinin öğrenilmiş bir temsilini ifade etmektedir. Elde edilen h_T temsilini hedeflerle eşlemek için üstüne standart bir MLP eklenir. Model eğitilirken geri yayılım sırasında kaybolan gradyan problemi, RNN'lerin performansını engellemekte ve uzun vadeli bağımlılıkları öğrenmeyi zorlaştırmaktadır (Malhi ve diğerleri, 2011).

LSTM ağı, geleneksel RNN'lerdeki uzun süreli diziler için kaybolan gradyanlar sorununu ortadan kaldırmak için Hochreiter ve Schmidhuber (1997) tarafından tasarlanan bir tür RNN mimarisidir. LSTM'ler içerdiği bir bellek hücresiyle bilgiyi daha uzun bir süre boyunca tutabilmektedir. Bu gelişmiş RNN varyantının arkasındaki temel fikir, uzun vadeli bağımlılık probleminden kaçınmak ve tekrarlayan her birimin farklı zaman ölçeklerinin bağımlılıklarını uyarlamalı olarak yakalamasını sağlamak için kapıların kullanılmasıdır. Bir LSTM, kısa ve uzun vadeli hücre durumlarını üç kapı aracılığıyla kontrol eder. Bunlar, belirtilen sırayla çalışan unutma, giriş ve çıkış kapılarıdır. Bir LSTM hücresinin temel yapısı Şekil 3.7'de gösterilmiştir.



Şekil 3.7. LSTM hücresi

Bu kapılar, önceki zaman adımı $t-1$'den elde edilen elemanlar ile, bir seferde yeni bir giriş verisinden istenen çıktıyı hesaplar. Denklem 3.5-3.10 arasındaki işlemler ilgili süreci tanımlamaktadır. Denklem 3.8'de yer alan c_t LSTM yapısının ana karakteristiği olmakla birlikte önceki tüm durumların bilgilerini içeren bir bellek kapsülünü ifade eder. Mevcut zamandaki bilgi girişi x_t ve bir önceki hücrenin kısa ve uzun vadeli durumları sırasıyla h_{t-1} ve c_{t-1}'dir. Kapıların çalışması sırasında, kapılardan üç sinyal üretilir ve sırasıyla f_t, i_t, g_t ve o_t olarak gösterilir. f_t, i_t, g_t ve o_t kapıları, kendi ağırlıkları (W_f, W_i, W_g, W_o) ve biasları (R_f, R_i, R_g, R_o) olan bağımsız sinirsel ağları temsil etmektedir.

Unutma kapısı, önceki uzun vadeli hücre durumu c_{t-1}'in bilgisinin ne kadarının tutulduğunu veya unutulduğunu kontrol eder. Unutma kapısı sinyali, bir önceki hücrenin kısa vadeli durumu, yani h_{t-1} ve mevcut hücrenin girişi x_t kullanılarak bir sigmoid fonksiyon $\sigma(.)$ aracılığıyla Denklem 3.5'teki gibi üretilmektedir.

$$f_t = \sigma\left(W_f x_t + R_f h_{t-1} + b_f\right) \tag{3.5}$$

Giriş kapısı, yeni bilginin mevcut hücre üzerindeki etkisini kontrol etmektedir ve Denklem 3.6 ile ifade edilir.

$$i_t = \sigma(W_i x_t + R_i h_{t-1} + b_i) \tag{3.6}$$

Mevcut hücre durumu aday değerleri g_t ile oluşturulur ve önceki uzun vadeli hücre durumu Denklem 3.7 ve Denklem 3.8 kullanılarak yeni bir duruma güncellenir. $tanh$

tanjant hiperbolik aktivasyon fonksiyonunu, ⊗ ise eleman bazında çarpma işlemini ifade etmektedir.

$$g_t = tanh(W_g x_t + R_g h_{t-1} + b_g) \tag{3.7}$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes g_t \tag{3.8}$$

Son olarak, LSTM hücresinin çıktısı h_t, çıkış kapısı (Denklem 3.9) ve hesaplanan hücre durumunun aktivasyonunun (Denklem 3.10) eleman bazında çarpımı ile hesaplanır.

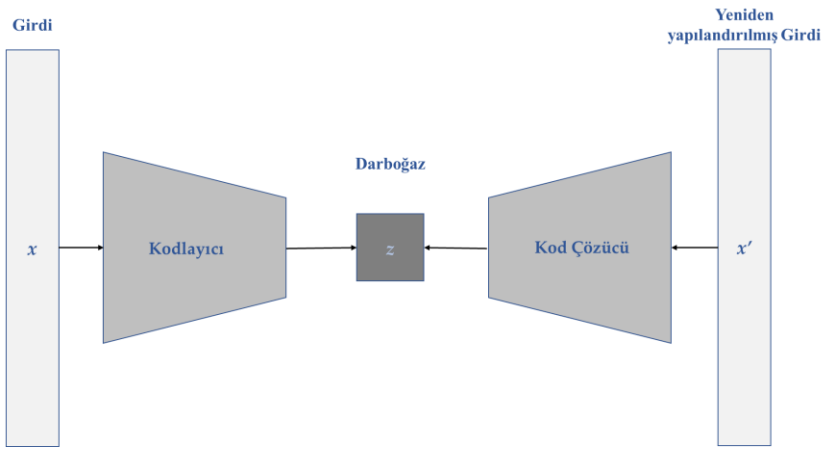
$$o_t = \sigma(W_o x_t + R_o x_t + b_o) \tag{3.9}$$

$$h_t = o_t \otimes \tanh(c_t) \tag{3.10}$$

Güncellenmiş uzun vadeli hücre durumu c_t ve kısa vadeli hücre durumu h_t daha sonra bir sonraki zaman adımına girdi olarak aktarılır. Bu hücre ve gizli durum güncelleme işlemi girdi dizisinin her zaman adımında tekrarlanır.

3.2.3. Otokodlayıcılar

Otokodlayıcılar, çıktı ile girdinin aynı olduğu ve veri sıkıştırma, öznitelik çıkarma ile boyut azaltma gibi denetimsiz öğrenme görevleri için kullanılan bir tür sinirsel ağ mimarisidir (Al Bataineh ve diğerleri, 2020; Song ve diğerleri, 2018). Bir otokodlayıcının ana bileşenleri, Şekil 3.8'de gösterildiği gibi bir kodlayıcı ağı, bir kod çözücü ağı ve bir darboğaz katmanı içerir.



Şekil 3.8. Oto kodlayıcı ağ yapısı

Kodlama genellikle ağdaki düğüm sayısını kademeli olarak azaltan bir dizi gizli katman aracılığıyla yapılır. Darboğaz, giriş verilerinin daha düşük boyutlu gizli uzay temsiline sıkıştırıldığı ağın ortasındaki katmandır. Darboğaz katmanının boyutu, gizli uzay temsilinin boyutunu belirler. Kod çözücü gizli uzay temsilini alır ve onu yeniden yapılandırılmış giriş verileri ile eşler.

Kodlayıcı gibi, kod çözücü de tipik olarak ağdaki düğüm sayısını kademeli olarak artıran bir dizi gizli katmandan oluşur. Otomatik kodlayıcı, orijinal giriş verileri ile kod çözücü tarafından yeniden yapılandırılan giriş verileri arasındaki farkı en aza indirecek şekilde eğitilir. Ortalama karesel hata (MSE) veya ikili çapraz entropi gibi bir kayıp fonksiyonu minimize edilir.

Parametre sayısının n ve otokodlayıcı ağının girdisinin $X = (x_1, x_2, \dots, x_n)^T$ olduğu durumda ağın çıktısı $X' = (x_1', x_2', \dots, x_n')^T$ iken; gizli katman z$= (z_1, z_2, \dots, z_m)^T$ olmaktadır. m, n'den büyük ya da küçük olabilirken, f ve f' aktivasyon fonksiyonları aynı veya farklı olabilmektedir. $m < n$ olduğunda boyut azaltma ile öznitelik çıkarımı gerçekleştirilmiş olmaktadır. Genellikle aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmaktadır. f fonksiyonu n-boyutlu X vektörünü m-boyutlu z vektörüne dönüştürürken, f' fonksiyonu ise m-boyutlu z vektörünü n-boyutlu X'vektörüne dönüştürmektedir. W, W' ağırlık matrislerini; b, b' ise biası ifade etmektedir. Otokodlayıcı ağında gerçekleştirilen bu işlemler Denklem 3.11 ve Denklem 3.12 ile gösterilmektedir.

$$z = f(Wx + b) \tag{3.11}$$

$$x' = f'(W'z + b') \tag{3.12}$$

Otokodlayıcılar değişkenler arasındaki karmaşık doğrusal olmayan ilişkileri yakalayabildiklerinden, bu onları doğrusal olmayan yapılara sahip yüksek boyutlu verileri temsil etmek için uygun hale getirir (Song ve diğerleri, 2018).

3.2.4. Öznitelik mühendisliği

Öznitelik mühendisliği, ham verilerin seçilmesi, işlenmesi ve dönüştürülmesini içeren bir süreçtir. Bu aşamada, verilerden anlam çıkarılması ve öğrenilebilir özniteliklerin

çıkarılması, bir makine öğrenimi algoritmasına girdi olarak kullanılabilecek nitelikte veri özniteliklerinin oluşturulmasını içerir (Liu, 2018).

- *Öznitelik Seçimi*

Özniteliklerin dikkatli bir şekilde seçilmesi, işlenmesi ve dönüştürülmesi, modelin genel başarısı için kritiktir. Bu aşama, veri setindeki önemli yapıları ve ilişkileri ortaya çıkarmak, özniteliklerin doğru bir şekilde öğrenilmesini sağlar ve böylece modelin daha genel, öngörülebilir şekilde davranmasına katkıda bulunur.

Öznitelik seçimi, bir veri kümesinde bulunan birçok öznitelik arasından en önemli ve anlamlı bilgi taşıyan öznitelikleri seçmeyi amaçlar. Veri setlerindeki gereksiz veya düşük bilgi taşıyan özniteliklerin çıkarılması, modelin genel performansını artırabilmekte ve eğitim sürecini optimize edebilmektedir. Öznitelik seçimi, veri setinin boyutunu azaltarak hesaplama maliyetini düşürebilir. Büyük ve karmaşık veri setlerinde kullanıldığında, bu süreç, modelin işleme sürelerini iyileştirebilir ve gereksiz özniteliklerin neden olduğu karmaşıklığı azaltabilir. Özenli bir öznitelik seçimi yapılmadığı taktirde, model aşırı öğrenerek (overfitting) yeni ve görünmeyen verilere karşı duyarlılığı artabilmektedir. Dolayısıyla, öznitelik seçimi, veri setlerinin daha etkili bir şekilde kullanılmasını sağlayarak makine öğrenimi modellerinin daha genel ve yüksek performanslı olmasına katkıda bulunur.

Öznitelik seçim yöntemleri, genellikle filtreleme, sarıcı ve gömülü yöntemler olarak üç kategoriye ayrılmaktadır. Filtreleme yöntemleri, pratikte uygulaması basit olan başarılı yöntemlerdir. Özniteliklerin performansını belirlemek için uygun bir değerlendirme kriteri belirlenir ve önceden belirlenen eşiğin altında kalan performans değerine sahip öznitelikler, kullanılacak öznitelik listesinden çıkarılırlar (Liu, 2018).

Sarıcı (Wrapper) yöntemler, özniteliklerin performansını önceden belirlenen bir model üzerinde değerlendirir. Geriye doğru eleme veya ileriye doğru seçim gibi stratejiler içerir. Özniteliklerin seçilebilmesi için modelin tekrar tekrar çalıştırılması gerektiğinden hesaplama maliyeti yüksektir (Miao ve Niu, 2016).

Gömülü (Embedded) yöntemler, öznitelik seçimi sürecini bir modelin eğitim aşamasıyla entegre eder. Yani, öznitelik seçimi, model eğitilirken otomatik olarak gerçekleştirilir (Khelif ve diğerleri, 2017). Örneğin, en az mutlak büzülme ve seçim operatörü (LASSO) ve Ridge regresyon gibi düzenleme yöntemleri, katsayıları sıfıra yakın olan özellikleri otomatik olarak elemek amacıyla kullanılır.

- *Öznitelik Ölçekleme*

Gerçek dünya uygulamalarında, üzerinde çalışılan probleme ait değişkenlerin/ özniteliklerin büyüklükleri farklı değer aralıklarına sahip olabilirler. Bazı özniteliklerin aldığı değerler, diğer özniteliklerin aldığı değerlere göre çok daha büyük veya çok daha küçük olabilmektedir. Bu değer aralığı yani ölçek farklılığı, tahmin sonuçlarının çok büyük veya çok küçük değerlerin etkisiyle yanlı olmasına sebep olur (Zhang ve diğerleri, 2017).

Öznitelik ölçeklendirme, özniteliklerin benzer ölçekte olmasını sağlamak için değerlerinin standartlaştırılmasına yardımcı olur. Min-max normalizasyonu, öznitelik ölçeklemede kullanılan yöntemlerden biridir. Min-max normalizasyon işlemi Denklem 3.13 ile gerçekleştirilir ve $x_{i,j}^{*}$, j. öznitelik için i. veri noktasının normalize edilmiş değerini, $x_{i,j}$ ise verilerin normalizasyondan önceki ham değerini ifade eder. x_j^{max} ve x_j^{min}, j. özelliğin sırasıyla maksimum ve minimum değerlerini gösterir.

$$x_{i,j}^{*} = \frac{x_{i,j} - x_j^{min}}{x_j^{max} - x_j^{min}}, \qquad \forall\, i, j \tag{3.13}$$

- *Öznitelik Çıkarımı*

Öznitelik çıkarma, öznitelik seçimini tamamladıktan sonra orijinal öznitelikleri yeni ve daha yönetilebilir bir sentetik öznitelik kümesine dönüştürür (De-La-bandera ve diğerleri, 2020). Orijinal özniteliklerin bir alt kümesini korumaya odaklanan öznitelik seçiminin aksine, öznitelik çıkarma tamamen yeni özniteliklerin oluşturulmasını içerir ve etkili bir şekilde veri setinin boyutunu azaltır.

Genellikle yeni elde edilen özniteliklerin sayısı, hesaplama kaynaklarını etkin şekilde kullanmak için orijinal özniteliklerin sayısından daha azdır. Öznitelik çıkarım süreci

cebirsel dönüşümler aracılığıyla gerçekleştirilir ve belirli bir optimizasyon kriterine uygun olarak yeni özniteliklerin orijinal veri setinden mümkün olan kadar çok ilgili bilgiyi korumasını sağlar.

Öznitelik seçimi ile karşılaştırıldığında, öznitelik çıkarma sadece bir değişken alt kümesini korumaktan öte, etkili bir şekilde yüksek boyutlu veri setlerinin anlamlı düşük boyutlu bir temsilini arar. Bu yaklaşım, bilgi kaybını azaltır ve ayırt edici gücü artırır, öznitelik çıkarmanın açıklanabilirliğin önemli senaryolarda tercih edilmesini sağlar (Zebari ve diğerleri, 2020).

Otokodlayıcılar, Temel Bileşen Analizi (PCA), İzometrik Haritalama (ISOMAP), Yerel Doğrusal Gömü (LLE) ve Doğrusal Diskriminant Analizi (LDA) yöntemleri öznitelik çıkarımında kullanılan yöntemlerdir.

- *Öznitelik Oluşturma*

Öznitelik oluşturma, mevcut veriden türetilen yeni özellikler aracılığıyla hedef değişkenle olan ilişkileri daha anlaşılır hale getirmeyi amaçlayan önemli bir teknik olarak kabul edilmektedir.

Özellikle, PdM alanında, varlık verilerinin öznitelik mühendisliği gereksinimini aşmak adına Derin Sinir Ağları'nın (DNN'ler) kullanımı, standart Makine Öğrenimi algoritmalarının benzer performans sergileyebileceği durumlarda yaygın bir eğilim olarak ortaya çıkmaktadır. Ancak, literatür, DNN'lerin varlık verilerinin öznitelik mühendisliği gereksinimini tamamen ortadan kaldırmadığını ve beklenen şekilde bu ihtiyacı tam anlamıyla aşmadığını göstermektedir (Aremu ve diğerleri, 2020). Esasen, DNN'ler de birer Makine Öğrenimi algoritmasıdır ve doğru performans elde etmek için yüksek kaliteli ve önceden iyi işlenmiş verilere ihtiyaç duymaktadır.

3.2.5. Değişim noktası tespiti

Zaman serisi analizi, tıp, havacılık, finans, iş, meteoroloji ve IoT gibi çeşitli alanlarda önemli rol oynamaktadır. Zaman serisi verileri, sistemlerin davranışını tanımlayan zaman içindeki ölçümlerin dizileridir. Bu davranışlar, zaman içindeki dış olaylardan veya içsel sistem dinamiklerinde meydana gelen farklılaşmadan dolayı değişebilmektedir

(Aminikhanghahi ve Cook, 2017). Değişim noktası tespiti, bir zaman serisinin istatistiksel özelliklerinin değiştiği noktaları bulma problemidir (Kawahara ve Sugiyama, 2009). Buna ek olarak, genellikle değişim noktası tespiti segmentasyon, kenar tespiti, olay tespiti ve anormallik tespiti gibi kavramlarla da ifade edilmektedir. Değişim noktası tespiti, kendisi birincil amaç olabilirken, bir zaman serisini homojen segmentlere ayırmak için bir ön işleme aracı olarak da kullanılabilmektedir (De Ryck ve diğerleri, 2021).

Literatürde yaygın olarak kullanılan, kesin sonuç veren ve hesaplama karmaşıklığı nispeten az olan Budanmış Tam Doğrusal Zaman (PELT) algoritması ile aslında temel işlevi değişim noktası tespiti değil, tek boyutlu veri üzerinde parçalı doğrusal model oluşturmak olan, pwlf isimli bir Python kütüphanesi de bulunan, parçalı doğrusal fonksiyonlar yöntemi aşağıda detaylandırılmıştır.

- ***PELT***

PELT algoritması, Jackson ve diğerleri (2005) tarafından geliştirilen optimum bölümlendirme algoritmasına dayanmaktadır, ancak dinamik bir program dahilinde budama adımı içermektedir. Jackson ve diğerleri (2005), optimum bölümlendirme algoritmasında, $y_i \in \mathbb{R}$ ve $(y_1, y_2, \ldots, y_n)$ veri dizisini, m değişim noktası sayısını ve τ pozisyonlarını temsil etmek üzere, Denklem 3.14'ü minimize etmeyi amaçlayan bir arama yöntemi önermiştir.

$$\sum_{i=1}^{m+1}[C(y_{\tau_{i-1}+1}, \ldots, y_{\tau_i}) + \beta] \tag{3.14}$$

Burada C segment için bir maliyet fonksiyonudur ve β aşırı uyuma karşı koruma sağlayan bir cezayı ifade etmektedir. Her bir değişim noktası konumu 1 ile n - 1 arasında bir tam sayıdır. $\tau_0 = 0$ ve $\tau_{m+1} = n$ olarak tanımlanır ve değişim noktalarının yalnızca $i < j$ olduğunda $\tau_i < \tau_j$ olacak şekilde sıralandığını varsayılır. Sonuç olarak, m değişim noktası, veriyi $m + 1$ segmente bölecek ve $i.$ segment $y_{(\tau_{i-1}+1):\tau_i}$ 'yi içerir. Optimal bölümleme yöntemi ilk olarak son değişim noktasını koşullandırarak başlar. Daha sonra maliyet fonksiyonunun optimal değerini, son değişim noktasından önceki verilerin optimal bölümlendirme maliyeti artı son değişim noktasından verilerin sonuna kadar olan bölümlendirme maliyeti ile ilişkilendirir.

PELT yöntemi, optimum bölümlendirme yöntemini budama ile değiştirir. Optimal bölümlendirme ve budamayı birleştirerek n'de doğrusal olan kesin ve verimli hesaplama maliyeti elde eder. Denklem 3.14'ün minimizasyonu olan $F(n)$, Denklem 3.15 ile ifade edilir.

$$F(n) = min\ \tau\{\sum_{i=1}^{m+1}[C(y_{\tau_{i-1}+1}, \dots, y_{\tau_i}) + \beta]\} \quad (3.15)$$

Son değişim noktası $\tau_m{}'$yi belirleyip bu değişim noktasına kadar olan verilerin en uygun segmentasyonunu Denklem 3.16 ile ifade edilmektedir.

$$F(n) = min\ \tau_m\{min\ \tau_|\tau_m[C(y_{\tau_{i-1}+1}, \dots, y_{\tau_i}) + \beta] + C(y_{\tau_m+1}, \dots, y_n)\} \quad (3.16)$$

Bu süreç aynı şekilde sondan ikinci, sondan üçüncü vs. değişim noktaları için de tekrarlanabilir. Bu belirlemenin özyinelemeli doğası, iç minimizasyonun Denklem 3.15'i yansıttığından, daha açık hale gelmektedir. Aslında iç minimizasyon F'ye eşittir ve bu nedenle Denklem 3.15, Denklem 3.17 olarak yeniden yazılabilir.

$$F(n) = \ min\ \tau_m\{F(\tau_m) + C(y_{\tau_m+1}, \dots, y_n)\} \quad (3.17)$$

$F(1)$'i hesaplanarak başlanır ve ardından $F(2), \dots, F(n)$ özyinelemeli olarak hesaplanır. Her adımda $\tau_{m+1}{}'$ e kadar en uygun segmentasyon saklanır. $F(n)$ değerine ulaşıldığında, tüm veri için en uygun segmentasyon belirlenmiş ve değişim noktalarının sayısı ve konumu kaydedilmiş olmaktadır.

Her adımda τ_m üzerindeki minimizasyon önceki tüm değerleri kapsar, örneğin $F(3)$ hesaplanırken minimizasyon $\tau_m = 0, 1, 2$'yi kapsar. PELT yönteminin hesaplama verimliliği, her adımda τ_m 'nin aday değerlerinin minimizasyondan çıkarılmasıyla elde edilir. Bu bağlamda budamanın özü, her iterasyonda gerçekleştirilen minimizasyondan asla minimum olamayacak τ değerlerini çıkarmaktır.

- ***pwlf***

Sürekli parçalı doğrusal fonksiyonları tek boyutlu verilere uydurmak için bir Python kütüphanesi olarak sunulmuştur. Sürekli parçalı doğrusal bir fonksiyon, doğru parçalarının sonlanma noktalarını temsil eden değişim noktalarına sahiptir. Değişim

noktası konumları biliniyorsa, en iyi sürekli parçalı doğrusal işlevi çözmek için en küçük kare uyumu kullanılır. Değişim noktaları bilinmiyor ancak istenen çizgi parçası sayısı biliniyorsa, en iyi kesme noktası konumlarını bulmak için global optimizasyon kullanılır. Bu optimizasyon süreci, farklı değişim noktası konumları için en küçük kareler uyumunu birkaç kez çözer.

x, bir 1D veri dizisi olmak üzere, n_b değişim noktası sayısı ve b_{n_b} son değişim noktasıdır. $n_b - 1$ çizgi segmentlerinin sayısıdır. Kütüphane, b_1'in ilk değer olduğunu ve b_{n_b}'nin tek boyutlu veri kümesinin son değeri olduğunu varsayar. Verilen herhangi bir $\boldsymbol{b}$ değişim noktası dizisi için, indiren β parametrelerini çözerek kalıntıların kareler toplamı hatasını en aza indiren bir en küçük kareler uyumu gerçekleştirilir. Kalıntıların kare toplamı $SSR(b)$, değişim noktası konumlarına bağlı bir fonksiyon olarak gösterilmektedir. pwlf kütüphanesi, ilk değişim noktasının $b_1 = x_1$ (veya en küçük x) ve son değişim noktasının $b_{n_b} = x_n$ (veya en büyük x) olduğunu varsayar. Kalıntıların genel kare toplamını en aza indiren değişim noktası konumlarını bulmak için bir optimizasyon problemi formüle edilir. Bilinmeyen $n_b - 2$ sayıda değişim noktası konumu bulunan optimizasyon probleminin özeti aşağıdaki gibidir:

$$minimize\ \ SSR(b), \qquad b = \left[b_2, \ldots, b_{n_b-1}\right]^T$$

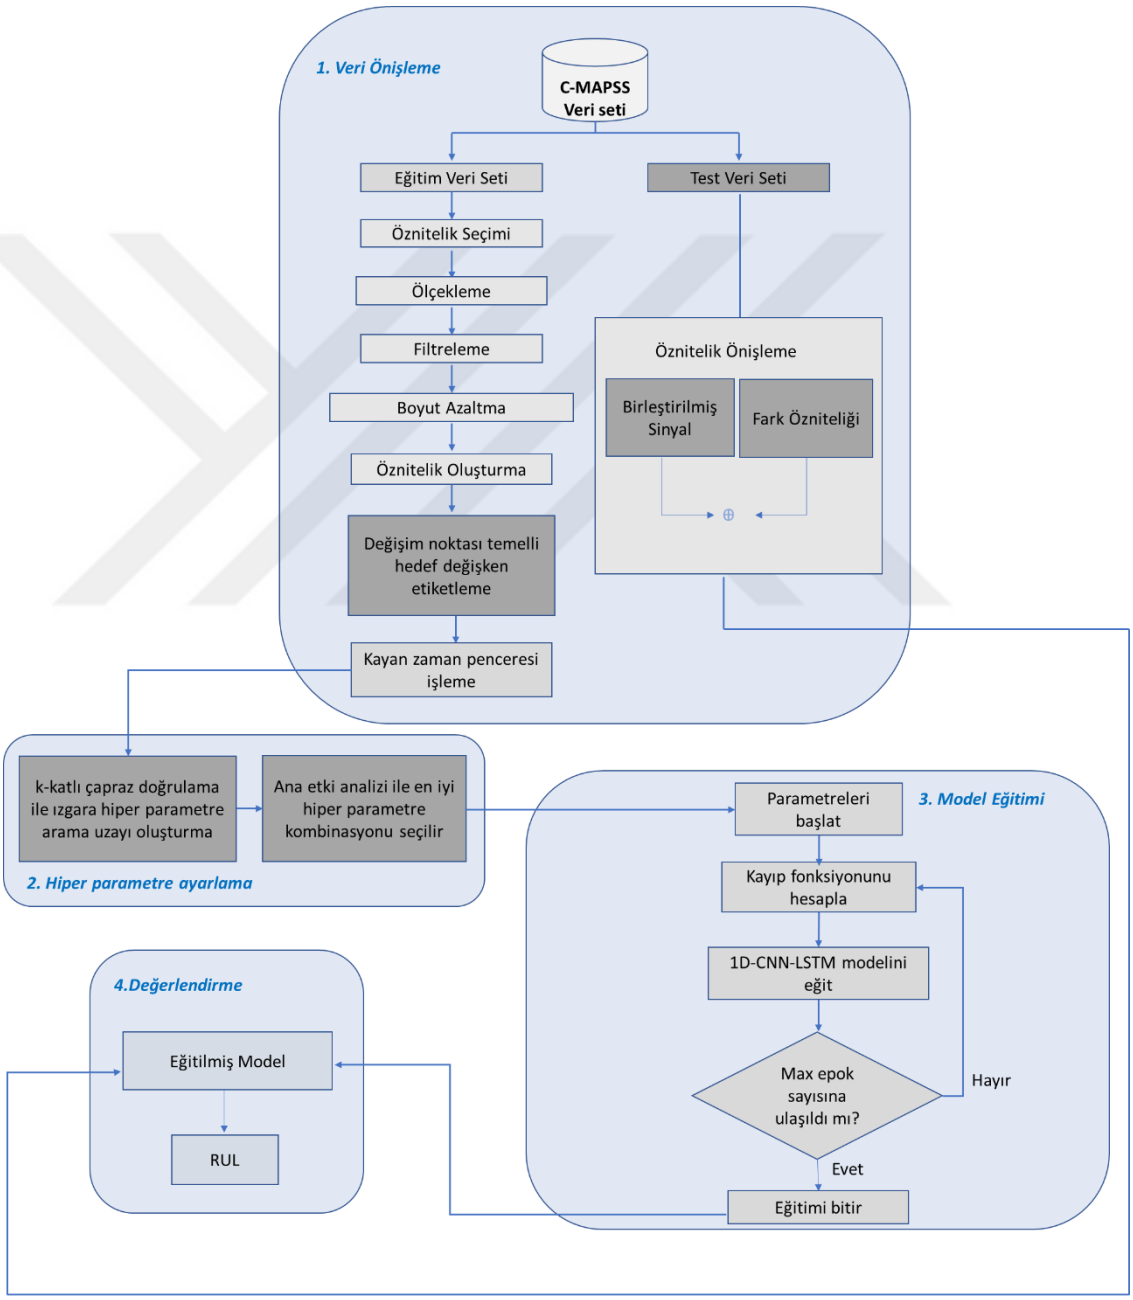
$$subject\ to\ x_1 \leq b_k \leq x_n,\ \ k = 1, 2, \ldots, n_b.$$

Diferansiyel Evrim tabanlı global optimizasyon, değişim noktaları bilinmediğinde ancak istenen segment sayısı bilindiğinde en iyi değişim noktası konumlarını bulmak için kullanılmaktadır.

pwlf yöntemi, kendi başına bir değişim noktası tespit algoritması olmamasına rağmen, PwL hedef etiketleme yaklaşımıyla aynı prensibe sahiptir. Çizgi/doğru segmenti parametresinin pratik kullanımı ile ilk değişim noktasının erken tespitinde yardımcı olur. pwlf tabanlı değişim noktası tespit yöntemi, çizgi segmenti parametresi sayesinde değişim noktalarının erken tespit edilmesi avantajını sunmaktadır. Ayrıca, motor bozulma süreçlerinin sağlık aşaması bölümlendirmesi problemiyle ilgili zorlukları ele alma potansiyeline de sahiptir.

3.2.6. Önerilen prognostik prosedür

Tez çalışması kapsamında değişim noktası tespiti ve öznitelik mühendisliğine dayalı hedef etiketleme yaklaşımı kullanılarak turbo fan motorların RUL tahmini için önerilen genel prosedür Şekil 3.9'da sunulmuştur. Bu prosedür, veri ön işleme, hiper parametre ayarlama, model eğitimi ve değerlendirme olarak dört temel aşamadan oluşmaktadır.



Şekil 3.9. Önerilen prognostik prosedür

Veri ön işleme aşaması, RUL tahmini için uygulanacak prosedürün ilk kritik adımdır. Veri setindeki hatalı, eksik değerlerin, gürültünün ve gereksiz bilginin azaltılarak veri kalitesinin iyileştirilmesini sağlar. Turbo fan veri seti, hatalı veya eksik bilgi içermediğinden ilk uygulanacak adım, veri setinde gereksiz bilgi içeren sensörlerin veri setinden çıkarılması yani öznitelik seçimi gerçekleştirilmesidir. Sensörlerden maksimum

bilgiyi sağlamak ve gereksiz bilgiden kaçınmak için, sinyal değerleri zaman içinde değişim gösteren sensörler seçilerek öznitelik seçimi yapılmıştır.

Sensörler farklı birimlerde ölçüm değerlerine sahip olduğundan öznitelikler arasındaki ölçek farklılığını gidermek, karşılaştırılabilirliği sağlamak ve yanlılığı ortadan kaldırmak için her bir sensör temelinde min-max normalizasyonu yapılmıştır. Veri setindeki gürültüden kaçınmak ve sensör değerlerindeki ana eğilimi ortaya çıkarmak için filtreleme yaklaşımı uygulanmıştır.

Seçilen sensör verilerinden tek bir kodlanmış sinyal oluşturmak için otomatik kodlayıcı tabanlı bir boyut azaltma yaklaşımı kullanılarak öznitelik çıkarma işlemi gerçekleştirilmiştir. Ayrıca, kodlanmış sinyal, bu tek sinyal üzerindeki değişim noktasına dayalı olarak hedef etiket değerini oluşturmak için kullanılmıştır. Bununla birlikte daha iyi öğrenme sağlamak için veri kümesindeki mevcut sinyal değerleri kullanılarak yeni bir öznitelik oluşturulmuş ve tahmin doğruluğunu artırmak için mevcut veri kümesine eklenmiştir.

Hedef RUL etiketlemesi, denetimli öğrenmede tahmin doğruluğunu etkileyen önemli bir faktördür. Turbo fanlar ait eğitim veri setinde önceden tanımlanmış hedef etiketler bulunmadığından, literatürde yaygın olarak kullanılan PwL fonksiyonu mevcut tez çalışmasında da benimsenmiştir. Veri kümesinde her motor için birden fazla sensör sinyali bulunmakla birlikte, bir oto kodlayıcı ağ kullanılarak gerçekleştirilen öznitelik çıkarım işlemi sonucu elde edilen tek boyutlu kodlanmış bir sinyal, her motor için tek bir değişim noktası belirlemek üzere kullanılmıştır. İki adet PwL fonksiyonu, bir optimizasyon algoritması kullanılarak kodlanmış sinyale uydurulmuş ve sinyalin değişim noktası değerinden sonra doğrusal olarak azaldığı bir değişim noktası elde edilmiştir. Değişim noktaları belirlendikten sonra, her bir motora özgü hedef RUL etiketleri oluşturulmuştur. Tüm veri ön işleme adımlarından sonra son girdi veri örneklerini

hazırlama işlemi, kayan pencere tekniği kullanılarak gerçekleştirilmiştir. Girdi verileri son olarak, kayan pencerenin her bir zaman adımı için birleştirilmiş sensör sinyali ve yeni fark özelliğinden oluşan 30 × 2 boyutunda şekillendirilmiştir. RUL tahmini 1D-CNN-LSTM hibrit ağı kullanılarak gerçekleştirilmiş ve temel 1D-CNN, temel LSTM ağları ve diğer geleneksel makine öğrenimi yöntemleriyle ayrı ayrı karşılaştırılmıştır. Eğitim aşamasında, kayan pencere yöntemleri kullanılarak hazırlanan örnekler, en iyi sinir ağı hiper parametrelerini bulmak için k-kat çapraz doğrulama yaklaşımında da kullanılmıştır. Eğitim aşamasında ana etki analizi kullanılarak hiper parametre değer aralıklarının tüm kombinasyonları için tahminler yapılmıştır.

Çapraz doğrulamada en iyi sonuçları veren hiperparametreler kullanılarak turbo fan motorların test verisi için RUL tahmini yapılmıştır. Değerlendirme aşamasında, tahmin değerleri ile temel gerçek değerler arasında karşılaştırma yapan değerlendirme metrikleriyle performans değerlendirmesi yapılmıştır.

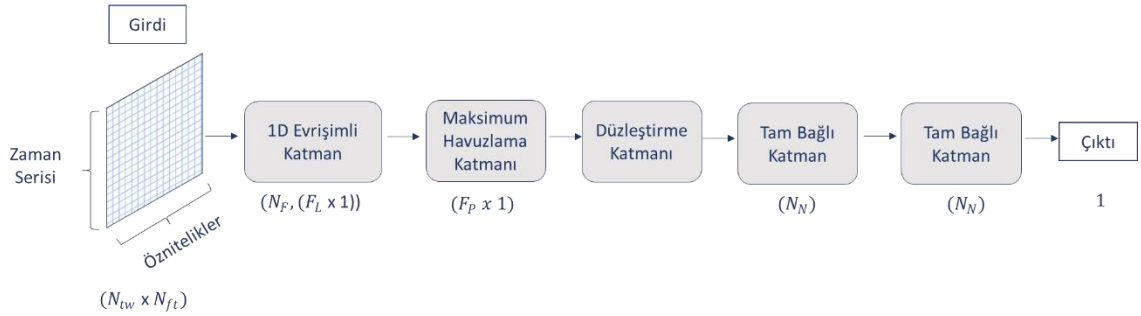
3.2.7. Önerilen sinirsel ağ yapısı

Tez çalışması kapsamında turbo fan motorlarda RUL tahmini için, temel 1D-CNN, temel LSTM ile bu temel sinirsel ağların güçlü özelliklerinden yararlanmayı hedefleyen, 1D-CNN ve LSTM sinirsel ağlarının seri olarak birleştirildiği 1D-CNN-LSTM hibrit sinirsel ağı kullanılmıştır.

C-MAPSS veri setinin kullanıldığı çalışmada öznitelik seçimi, ölçeklendirme ve filtreleme işlemlerinin ardından, çok sensörlü turbo fan motorlarını tek bir sinyale indirgeyerek değişim noktasını tespit etmeye yardımcı olan bir ön işleme adımı olarak boyut azaltma tabanlı bir otomatik kodlayıcı kullanılmıştır. Girdi örneği $N_{tw} \times N_{ft}$ şeklinde 2 boyutlu bir tensör olarak şekillendirilmiştir. N_{tw} ve N_{ft} sırasıyla zaman dizisi uzunluğunu ve öznitelik sayısını göstermektedir.

- *Temel CNN*

Temel CNN'de, girdiden uzamsal özniteliklerin çıkarımını sağlamak için 1D evrişimli katman kullanılmıştır. Evrişimli katman kullanılan filtre sayısı N_f, filtre boyutu ise F_L ile temsil edilmektedir ve temel CNN mimarisi Şekil 3.10'da gösterilmiştir.

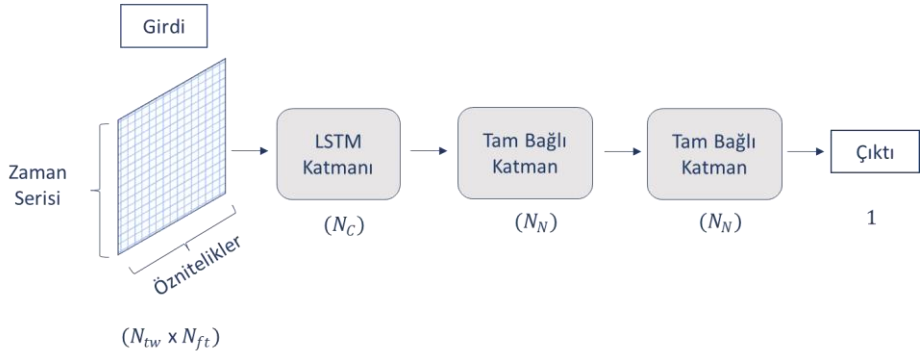


Şekil 3.10. Temel CNN

Öznitelik haritasının boyutlarını koruyabilmek için "0" değerinin kullanıldığı aynı kenar dolgusu uygulanmıştır. Her bir öznitelik haritasının yeniden boyutlandırıldığı havuzlama katmanında maksimum havuzlama kullanılmıştır ve havuzlama büyüklüğü ise F_P ile temsil edilmektedir. Tamamen bağlı katmanlar, öznitelik matrisini vektöre indirgemekte ve elde edilen bu öznitelik vektörlerini örneklerin hedef RUL etiketleriyle haritalamaktadır. N_N, tamamen bağlı katmanda kullanılan nöron sayısını temsil etmek için kullanılmıştır. Sonu olarak RUL tahminleri yapmak için bir nörona sahip tamamen bağlı bir çıkış katmanı yerleştirilmiştir.

- *Temel LSTM Ağı*

Temel LSTM ağında, girdiden zamansal özniteliklerin çıkarımını sağlamak için ilk katman olarak LSTM katmanı kullanılmıştır. N_C, LSTM katmanındaki birim sayısını temsil etmekle birlikte temel LSTM sinirsel ağ mimarisi Şekil 3.11'de gösterilmiştir.



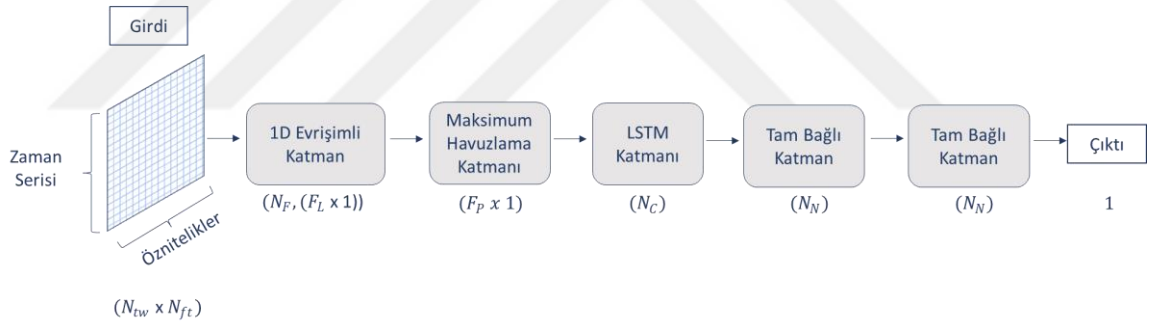
Şekil 3.11. Temel LSTM Sinirsel Ağı

LSTM katmanıyla zamansal öznitelikleri çıkarılan veriler, tam bağlı katmanlar yardımıyla vektör boyutuna indirgenmektedirler. İndirgenen öznitelik vektörler, ilgili örneklerin hedef RUL etiketleriyle haritalanmakta ve tam bağlı tek bir nöron ile RUL tahmini yapılmaktadır.

- *1D-CNN-LSTM Hibrit Ağı*

Temel CNN ve temel LSTM sinirsel ağlarının, uzamsal ve zamansal öznitelik çıkarımı özelliklerinden faydalanmak amacıyla, bu iki temel sinirsel ağın seri bağlandığı hibrit bir 1D-CNN-LSTM sinirsel ağı oluşturulmuş ve Şekil 3.12'de gösterilmiştir.

1D-CNN ile elde edilen öznitelik haritaları, ilgili veri setinin uzamsal özniteliklerinin çıkarılmasını sağlarken, havuzlama katmanında yeniden boyutlandırılmıştır. LSTM katmanı ile öznitelik haritalarının zamansal özellikleri elde edilmesi sağlanmış ve tam bağlı katmanlar yardımıyla hedef RUL etiketleri ile eşlenip, çıktı katmanında RUL tahmini yapılmaktadır.



Şekil 3.12. Önerilen 1D-CNN- LSTM Sinirsel Ağı

3.2.8. Değerlendirme metrikleri

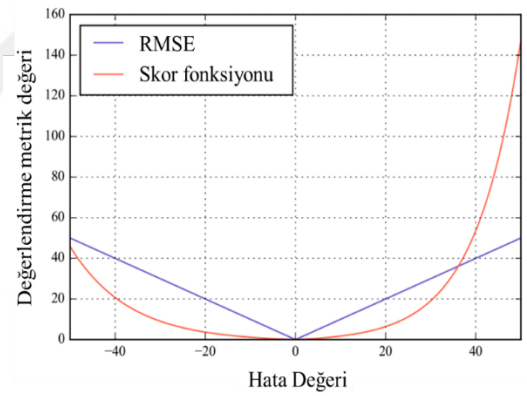
Tez çalışmasında, RUL tahmini için önerilen prognostik prosedürün performansını değerlendirmek için skor fonksiyonu, RMSE ve Ortalama Mutlak Yüzde Hata (MAPE) olmak üzere üç performans ölçütü kullanılmıştır. RMSE ve skor fonksiyonu $d_i = RUL_{tahmin} - RUL_{gerçek}$ tanımını kullanmaktadır. d_i tahmin edilen RUL ile gerçek RUL arasındaki farkı ifade etmektedir. Uluslararası Prognostik ve Sağlık Yönetimi Konferansı (PHM08) Veri Yarışması ("PHM 2008 Challenge | NASA Open Data Portal.) tarafından önerilen puanlama fonksiyonu Denklem 3.18 ile tanımlanmaktadır.

$$skor = \sum_{i=1}^{N} S_i, \quad S_i = \begin{cases} e^{\frac{-d_i}{13}} - 1, & d_i < 0 \\ e^{\frac{d_i}{10}} - 1, & d_i \geq 0 \end{cases} \tag{3.18}$$

Denklem 3.18'de N test örneklerinin sayısıdır. Skor fonksiyonu asimetrik bir fonksiyondur ve sistem arızasının ciddi olumsuz sonuçları nedeniyle, geç tahminlere erken tahminlerden daha büyük bir ceza puanı vermektedir. Tahmin performansı için standart bir değerlendirme ölçütü olan RMSE hem erken hem de geç tahminler için eşit cezalar verir ve Denklem 3.19 ile hesaplanır.

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N} d_i^2} \tag{3.19}$$

Skor fonksiyonu ve RMSE değerleri ne kadar düşükse, tahmin performansının o kadar başarılı olmaktadır. Şekil 3.13, iki değerlendirme metriği arasındaki karşılaştırmayı göstermektedir.



Şekil 3.13. RMSE ve skor fonksiyonu karşılaştırması

MAPE, gerçek değerlerle tahmin edilen değerler arasındaki mutlak yüzde hatalarının ortalama değerini hesaplar ve Denklem 3.20 ile gösterilir. MAPE' nin değeri genellikle yüzde cinsinden ifade edilir ve daha düşük bir MAPE değeri, daha iyi bir tahmin performansını gösterir.

$$MAPE = \frac{100}{N}\sum_{i=1}^{N}\left|\frac{RUL_{gerçek} - RUL_{tahmin}}{RUL_{gerçek}}\right| \tag{3.20}$$

4. BULGULAR ve TARTIŞMA

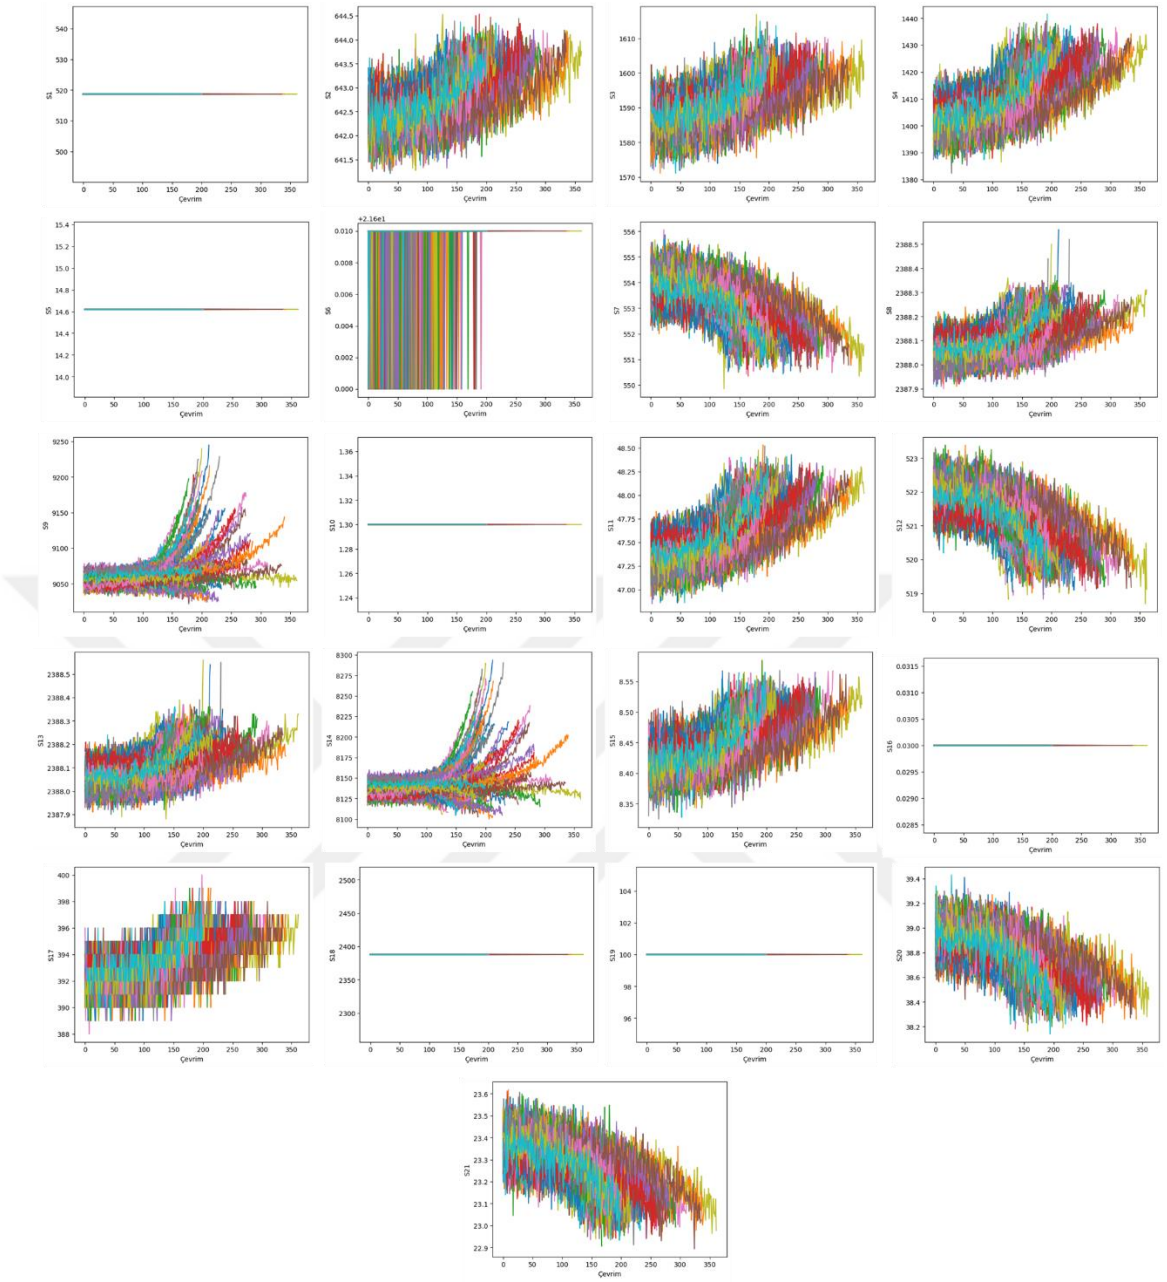
Bölüm 4.1'de, Şekil 3.9'da akış diyagramı gösterilen metodolojinin uygulama süreçlerine yer verilmiş, Bölüm 4.2'de önerilen prognostik prosedürün etkinliğine ilişkin deneysel sonuçlar karşılaştırmalı olarak ele alınmıştır.

4.1. Bulgular

Tez çalışmasının bu bölümünde turbo fan motorlarında RUL tahmini için önerilen prognostik prosedür ile prognostik süreç içerisindeki her bir adıma ilişkin uygulama detaylarına ve RUL tahmininde kullanılan derin sinirsel ağ yapısına detaylı olarak yer verilmiştir.

4.1.2. Veri ön işleme ve öznitelik seçimi

Çoklu, çok değişkenli zaman serisi olarak nitelendirilen C-MAPSS veri seti, her biri bir özniteliği temsil eden, 21 adet sensörden elde edilen zaman serilerinde oluşmaktadır. Çok değişkenli zaman serilerinde, fazla boyutluluğun yarattığı hesaplama zorluğu, işlem uzunluğu, karmaşıklık gibi sorunların üstesinden gelebilmek, gereksiz bilgilerden kaçınabilmek ve yalnızca bilgi içeren sensörlerle daha doğru tahmin yapabilmek adına, çeşitli sensör seçim yöntemleri uygulanmıştır. Öngörülebilirlik, monotonluk, eğilimlilik ve sağlamlık gibi değerleri hesaplanan sensörlerden, bu değerleri önceden belirlenen bir eşik değerinin üstünde değere sahip olanların seçildiği, sensörlerin önem ve katkı derecelerinin incelendiği detaylı analizleri içeren birçok çalışma literatürde yer almaktadır (Bektas ve diğerleri, 2019; de Cheveigné ve Nelken, 2019; Gong ve diğerleri, 2022; Zhang ve diğerleri, 2020). Eğitim veri setinde yer alan 100 adet motora ilişkin tüm sensör değerlerini içeren grafikler Şekil 4.1'de gösterilmiştir.



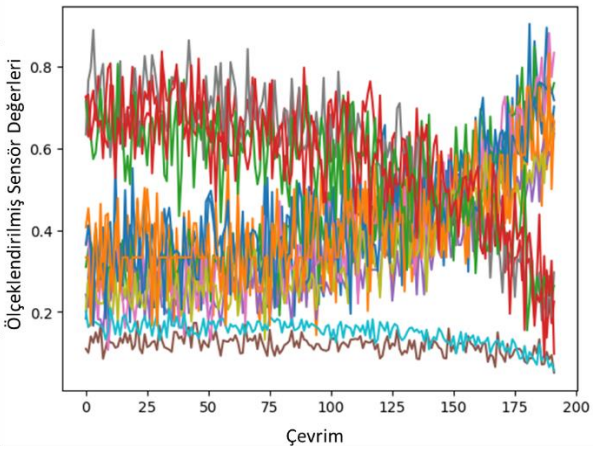
Şekil 4.1. FD001 eğitim veri setindeki 100 motora ait sensör değerleri

Şekil 4.4'te yer alan grafikler incelendiğinde, bazı sensör ölçümlerinin motorun kullanım ömrü boyunca sabit değerlere sahip oldukları görülmektedir. Çizelge 4.1'de sensörler artan, azalan ve sabit eğilim gösteren sensörler olarak kategorize dilmiştir. Sabit değerleri sensörler bozulma bilgisi sağlamadığından, RUL tahmini için kullanılacak öznitelik listesinden çıkarılmış, artan ve azalan eğilim gösteren 14 adet sensör, öznitelik olarak seçilmiştir (Heimes, 2008; Li ve diğerleri, 2018; Wang ve diğerleri, 2022).

Çizelge 4.1. FD001 veri setindeki sensör verilerinin trendi

Trend	Sensörler
Artan	2, 3, 4, 8, 9, 11, 13, 15, 17
Azalan	7, 12, 14, 20, 21
Sabit	1, 5, 6, 10, 16, 18, 19

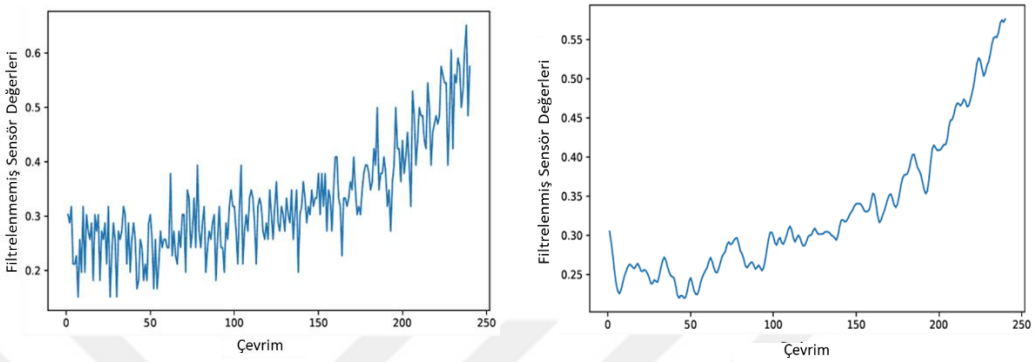
C-MAPSS veri setinde, farklı sensörlerden alınan ölçümler büyüklük ve birimler açısından farklılık göstermektedir. Modeldeki düşük ve yüksek büyüklüklerin tahmin sonuçlarına olan yanlı etkisini bastırmak için sensör verilerinin standardize edilmesi gerekmektedir. Sensör ölçümleri, Bölüm 3.2.4'te belirtildiği gibi, özellik mühendisliği sürecindeki özellik ölçeklendirme adımını temsil eden min-maks normalleştirme Denklem 3.13 kullanılarak [0, 1] aralığında ölçeklendirilmiştir. Örnek olarak, 1 numaralı motora ait 14 sensörün normalleştirilmiş yaşam döngüsü verileri Şekil 4.2'de gösterilmektedir.



Şekil 4.2. FD001 eğitim veri setindeki #1 numaralı motora ait 14 adet sensörün ölçeklendirilmiş değerleri

C-MAPSS veri seti gürültü içeren bir veri setidir. Gürültü, veri üzerinde zig-zag şeklindeki sapmalara neden olduğu gibi öğrenmede ana eğilimden uzaklaşılmasına neden olmaktadır ve etkisi mümkün olduğunca azaltılmalıdır. Simüle edilen sensör sinyallerini daha düzgün hale getirmek, öğrenmeyi kolaylaştırmak ve ana eğilimi ortaya çıkarmak için alçak geçiren filtre yöntemi kullanılmıştır. Alçak geçiren filtre, düşük frekanslı sinyalleri geçirir ve yüksek frekanslı sinyalleri zayıflatır, böylece küçük dalgalanmaları ve aykırı değerleri ortadan kaldırırken uzun vadeli eğilimleri korur (de Cheveigné ve

Nelken, 2019). Veri kayıtlarının örnekleme frekansı 1 Hz' dir. Tasarlanan alçak geçiren filtre, 0,08 Hz kritik frekansa sahip birinci dereceden bir filtredir. FD001 alt veri setinden rastgele seçilen bir motor sensörünün sinyali filtreli ve filtresiz olarak Şekil 4.3'te gösterilmektedir.



(**a**) (**b**)

Şekil 4.3. Filtreleme (a) filtreleme öncesi ve (b) filtreleme sonrası

4.1.3. Otokodlayıcı tabanlı öznitelik çıkarma

Öznitelikler arasından, turbo fan motorların bozulma süreciyle ilgili bilgi sağlayan 14 adet öznitelik seçilmiştir. Seçilen 14 adet öznitelik, mevcut öznitelik kümesinin bir alt kümesini oluşturmuş ancak etkili bir şekilde çok boyutluluk problemini çözüme kavuşturamamıştır.

Veri setinin etkin şekilde boyutunu azaltmak, öznitelikler üzerindeki mevcut bilgiden maksimum faydayı sağlayacak ve 14 adet özniteliği temsil edecek yeni bir öznitelik oluşturmak için, üç katmanlı tamamen bağlı nöronlardan/düğümlerden oluşan bir oto kodlayıcı sinirsel ağı kullanılmıştır. Oto kodlayıcı ağın hiper parametrelerini oluşturan epok/dönem sayısı, parti büyüklüğü ve gizli katmandaki düğüm sayısına ilişkin değerlendirme aralıkları Çizelge 4.2'de gösterilmiştir.

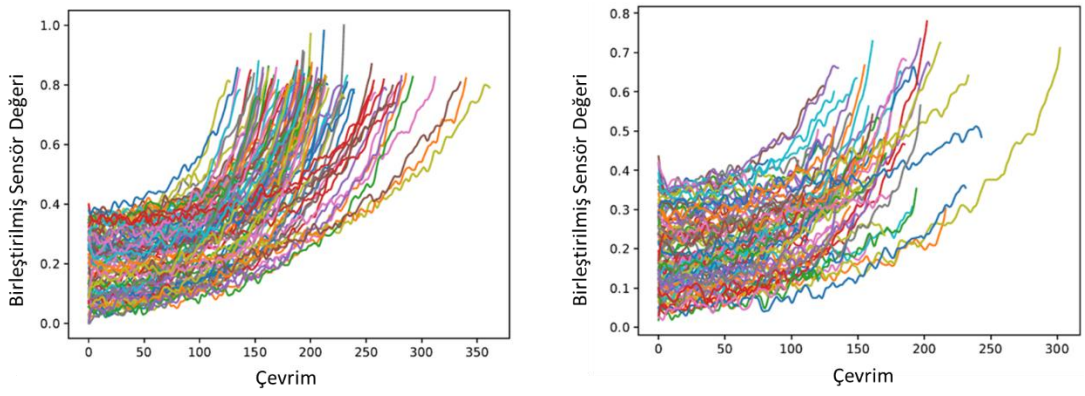
İlgili hiper parametrelerden epok/dönem sayısı veri setinin büyüklüğünü dikkate alınarak, öğrenmeyi en iyi şekilde sağlamak ve aşırı öğrenmeden kaçınmak amacıyla minimum 20, maksimum 40 olacak şekilde belirlenmiştir. Parti büyüklüğü hiper parametresi için belirlenen değer aralıkları; veri setinin boyutu da dikkate alınarak öğrenmeyi hızlandıracak küçük parti büyüklüğü değerlerini ve genelleştirmeyi sağlayacak büyük

parti büyüklüklerini değerlendirmemize olanak sağlayacak şekilde belirlenmiştir. Oto kodlayıcı sinirsel ağının katman sayısı hem bilgi kaybını engelleyecek hem de aşırı öğrenmeden kaçınmayı sağlayacak şekilde 3 katman olarak belirlenmiştir. Gizli katmandaki düğüm sayısı aralığı ise, bir oto kodlayıcı ağ içerisinde darboğaz katmanında elde edilmesi istenen veri boyutuna, veriyi en iyi temsil edecek, katmanlardaki düğüm sayıları arasında büyük farkları azaltacak ile veri kaybını en aza indirecek şekilde belirlenmiştir. İlgili hiper parametre ve değer aralıkları dikkate alındığında, tüm hiper parametre değer aralıkları arasından (4x3x3) hata değerlerini minimize ederek en iyi performans gösteren sinirsel ağ hiper parametre kombinasyon seçilmiştir.

Çizelge 4.2. Oto kodlayıcı ağında değerlendirilen hiper parametre değerleri

Hiper parametreler	**Değer Aralığı**
Epok/Dönem sayısı	(20, 25, 30, 40)
Parti büyüklüğü	(64, 128, 256)
Gizli katmandaki düğüm sayısı	(5, 7, 10)

Hiper parametrelerden epok/dönem sayısı 30 ve parti büyüklüğü 128 olarak ayarlanmıştır. Girdi katmanındaki ve çıktı katmanındaki düğüm sayısı seçilen özniteliklerin sayısına eşittir ve 14'tür. Şekil 3.8'de "Kodlayıcı" ve "Kod Çözücü" olarak gösterilen gizli katmanlardaki düğüm sayısı 7 olarak ayarlanmıştır ve darboğaz boyutu, aynı zamanda girdinin arzulanan boyutu ise 1'dir. Kayıp fonksiyonu olarak MSE kullanılmıştır ve kayıp fonksiyonunu minimize etmek için uyarlanabilir moment tahmini (Adam) kullanılmıştır. Eğitim veri setinin %80'i eğitim sürecine ayrılmış, kalan %20'lik kısım ise doğrulama amacıyla kullanılmıştır. Öznitelik çıkarım işlemi hem eğitim hem de test veri kümelerine uygulanmıştır. Öznitelik çıkarma işleminden sonra her bir motor için elde edilen yeni özniteliğe ait değerler Şekil 4.4'te gösterilmektedir. Farklı renklerdeki sinyaller veri kümesindeki her bir motoru temsil etmektedir.



(**a**) (**b**)

Şekil 4.4. Öznitelik çıkarımı (a) eğitim veri setine ait 100 motor (b) test veri setine ait 100 motor

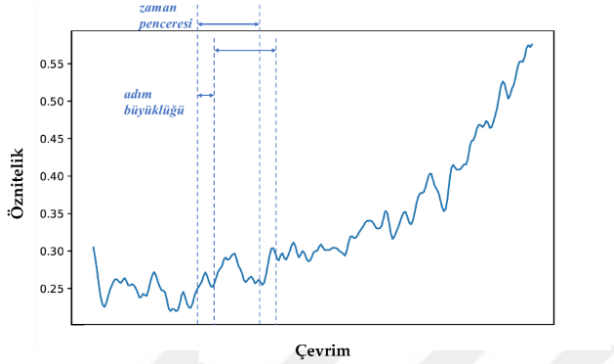
4.1.4. Kayan zaman penceresi ile işleme

Zaman serisi tabanlı prognostik problemlerde, RUL tahmini için zamansal bilgi önem arz etmektedir. Zamansal dizi verilerinin, mevcut bozulma durumu hakkında tek zamanlı adım verilerinden daha fazla bilgi içerdiği varsayıldığından, bu çalışmada zamansal bilgilerden yararlanmak için kayan bir zaman penceresi stratejisi benimsenmiştir. Zaman penceresi, belirli bir zaman penceresi uzunluğuna sahip ve veriler üzerinde tek bir zaman adımı kayacak şekilde oluşturulmuştur. L arızaya kadar motor çevrim sayısı ve tw zaman penceresi uzunluğu olmak üzere, motor verilerinden $L - tw + 1$ adet örnek çıkarılır. t zamanındaki örnek Denklem 4.1'deki gibi yazılır.

$$x_t = [x_{t-tw+1}, x_{t-tw+2}, \ldots, x_t], \qquad t = tw, \ldots, L \tag{4.1}$$

Daha uzun zaman pencereleri, daha fazla bozulma bilgisi içererek daha iyi performans sağlarlar (Chen ve diğerleri, 2021; Li ve diğerleri, 2018). Ancak, daha uzun bir zaman penceresi hesaplama karmaşıklığını artırır. Burada, test veri kümesindeki en kısa çevrim uzunluğuna sahip motorun çevrim uzunluğunu (31) aşmamak için pencere boyutu 30 olarak ayarlanmıştır. Zaman pencereleri üst üste örtüşecek şekilde tasarlanmış ve adım boyutu "1" olarak ayarlanmıştır. Kayan zaman penceresi işlemi Şekil 4.5'te gösterilmektedir. Verilen pencere uzunluğu ve adım boyutu kullanılarak 17731 eğitim örneği elde edilmiştir. Test ve eğitim aşamaları sırasında, her bir motorun RUL etiketi

olarak, ilgili motorun son zaman penceresinin son sensör ölçüm verilerine ait RUL etiketi kullanılmıştır. FD001 için test veri setindeki motor sayısı 100 olduğundan, tahmin modelini test etmek için 30 adımlı zaman pencerelerinden oluşan 100 adet örnek kullanılmıştır.



Şekil 4.5. Kayan zaman penceresi

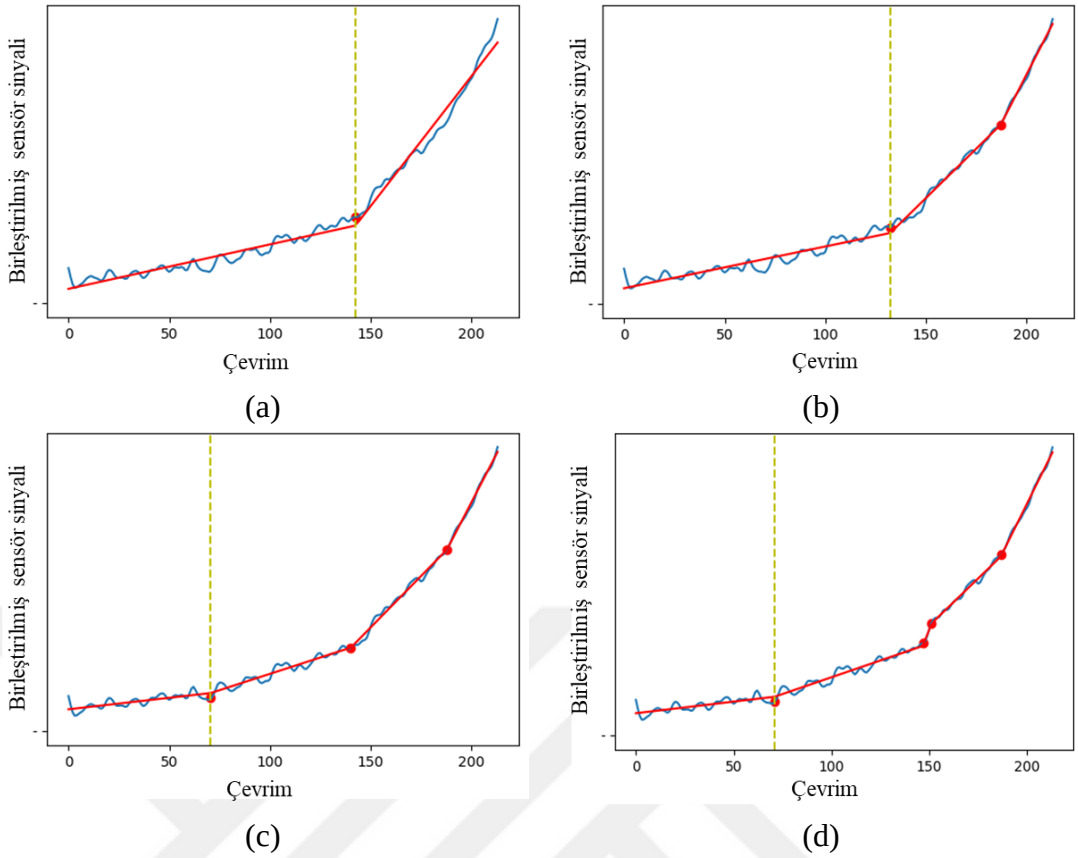
4.1.5. Değişim noktası temelli hedef değişken etiketleme

Turbo fan motorlarına ait eğitim veri setinde hedef RUL etiketleri bulunmamaktadır. Literatürde hedef RUL etiketlemesi için çeşitli etiketleme yöntemleri kullanılmıştır. Hedef RUL etiketlemesi için en çok kullanılan yöntemlerden biri Heimes (2008) tarafından önerilen PwL bozulma modelidir. PwL tabanlı RUL etiketlemede, hedef RUL başlangıç dönemi için normal/sağlıklı çalışma koşulları nedeniyle sabit kabul edilmekte ve sistemin bozulmaya başladığı belirli bir noktadan sonra doğrusal olarak azalmaktadır. Genel olarak, çalışmalarda PwL fonksiyonunun sabit kısmının herhangi bir çevrim için maksimum RUL değeri olarak yaklaşık 120-130 değerini kullanmaktadır (Heimes, 2008; Huang ve diğerleri, 2019; Peng ve diğerleri, 2022). Tüm motorlar için tek bir sabit maksimum RUL değeri genelleme için uygun görünse de her bir motorun farklı bir yaşam döngüsü uzunluğu ve bozulma süreci vardır. Değişim noktası tespiti için sürekli PwL fonksiyonlarını tek boyutlu zaman serisi verilerine uydurmak üzere Python kütüphanesi pwlf kullanılmıştır (Jekel ve Venter, 2019). Her bir motorun sensör verilerindeki en erken değişim noktasını bulmak için, istenen doğru sayısı parametresi, sensör verisi üzerindeki ilk değişim noktası anlamlı bir şekilde değişim göstermeyene dek arttırılmıştır. Değişim noktasının ve değişim noktasına bağlı maksimum RUL değeri ve hedef etiketlerinin belirlenmesi için kullanılan prosedür Algoritma 1'de gösterilmiştir.

Algoritma 1 Değişim noktası ve maksimum RUL belirleme

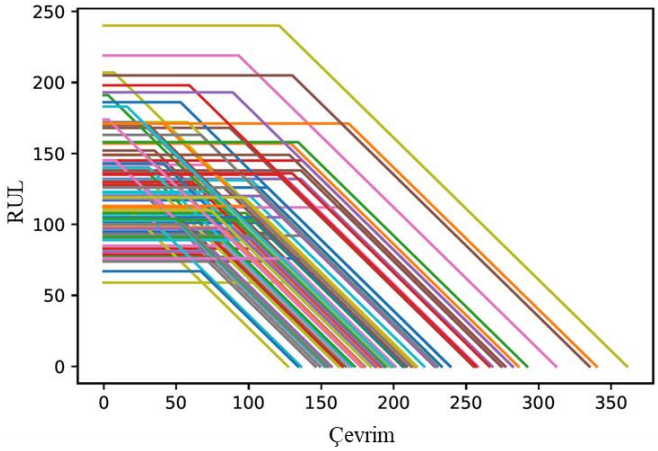
girdi: Veri dizisi $X = (x_1, x_2, \ldots, x_T)$, pwlf
parametreler: $T \leftarrow$ dizi uzunluğu
çıktı: maks_rul, fcp
başla
    i = 1
    $x \leftarrow pwlf(i, X)[0]$
    while True **do**
        $y \leftarrow pwlf(i+1, X)[0]$
        $diff \leftarrow y - x$
        if y == x ***or*** diff > threshold ***then***
            $fcp \leftarrow y$
            break
        else:
            x $\leftarrow y$
            i $\leftarrow$ i + 1
    $maks_rul \leftarrow T - fcp$
son

Şekil 4.6 rastgele seçilen bir motor için Algoritma 1'deki süreci göstermektedir. Mavi çizgiler çıkarılan sensör sinyallerini, kırmızı çizgiler uydurulan doğrusal çizgileri ve kesikli sarı çizgiler ilk kesme noktasını temsil etmektedir. İlk çizgi segmentinin son noktası sensör verilerinin ilk değişim noktasını verir. Şekil 4.6'da çizgi segmentleri ikiden beşe kadar kademeli olarak artırılmıştır. İki segment olduğunda ilk değişim noktasının tespitinin geciktiği açıkça görülmektedir. İlk değişim noktasının tespitinde kayda değer bir iyileşme olmadığı için istenen çizgi segmenti parametresi sayısı "5" olarak belirlenmiştir.



Şekil 4.6. Doğru sayısı parametresini değiştirerek FD001'den rastgele seçilen bir motorun değişim noktası tespit süreci (a) 2 doğru (b) 3 doğru (c) 4 doğru (d) 5 doğru

Değişim noktası tespit işlemi, iki PwL segmenti için tüm motorlara uygulandığında, bu motorların hedef RUL etiketleri Şekil 4.7'de gözlemlendiği gibi olmaktadır.



Şekil 4.7. Eğitim veri setindeki tüm motorlara özgü RUL etiketleri

4.1.6. Öznitelik oluşturma

Önerilen prognostik prosedürün tahmin performansını artırmak amacıyla, bu tez çalışmasında turbo fan motorun bozulma eğilimini temsil etmek üzere yeni bir öznitelik oluşturulmuştur. Motorun çalışmaya başladığı ilk sensör ölçümü ile her bir zaman adımındaki sensör ölçümü arasındaki fark hesaplanarak ve yeni bir öznitelik olarak veri setine eklenir. Yeni öznitelik oluşturma süreci Algoritma 2'de gösterilmiştir.

Algoritma 2 Yeni öznitelik oluşturma ve ekleme

---

girdi: Veri dizisi $X = (x_1, x_2, \ldots, x_T)$
parametreler: $T \leftarrow$ dizi uzunluğu, $t \leftarrow$ mevcut zaman adımı $t \in [1, T]$
çıktı: Genişletilmiş veri dizisi X'
başla
  D ← [ ]
  for $t \leftarrow 1$ to T **do**
    $fark_t \leftarrow x_t - x_t$
    $D \leftarrow D + [fark_t]$
  son
$X' \leftarrow X$ +D
son

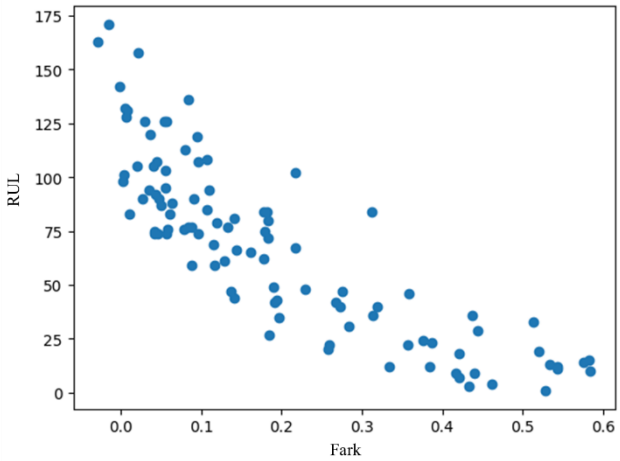
Oluşturulan fark özniteliği ile motor bozulma eğilimi arasındaki ilişkiyi göstermek amacıyla, fark ve hedef değeri arasındaki korelasyon katsayısı Denklem 4.2 ile hesaplanmıştır.

$$\rho_{x,y} = \frac{\sum(x_i - x)(y_i - y)}{\sqrt{\sum(x_i - x)^2 (y_i - y)^2}} \tag{4.2}$$

Denklem 4.2'de kullanılan x_i ve y_i sırasıyla girdi değişkeni ve hedef değişkeni RUL için ayrı örnek noktalarıdır ve x ile y sırasıyla bu örneklerin ortalama değerleridir. Böylece, varsayılan korelasyonlu sonuçlara dayanarak, RUL tahmini için eğitim veri kümesine yeni bir fark özniteliğinin eklenmesi amaçlanmaktadır.

Veri kümesinin tamamı, yalnızca tüm motorlardan elde edilen sensör okumalarından oluşmaktadır. Sensör verileri ile RUL arasındaki ilişkiyi bulmak için, yeni fark özniteliğinin, yani eğitim veri setinin sensör sinyallerindeki son ve ilk veri noktası arasındaki farkın verilen RUL değerleriyle korelasyonunu araştırılmıştır. İlişkinin hem eğitim hem de test veri kümesi için geçerli olduğundan emin olmak için test veri

kümesinde olduğu gibi eğitim veri kümesinde de motorların sinyalleri rastgele çevrim değerlerinde kesilmiştir. Şekil 4.8'deki dağılım diyagramı böyle bir ilişkinin varlığını işaret etmektedir.



Şekil 4.8. Eğitim veri setindeki tüm motorlar için RUL ile son ve ilk veri noktaları farkı arasındaki ilişki

RUL ile sensör sinyallerindeki son ve ilk noktaların farkı arasında Denklem 4.2 kullanılarak korelasyon analizi yapıldıktan sonra, korelasyon katsayısı p-değeri < 0,00 ile ρ = -0,85 olarak bulunmuştur. Buna dayanarak, RUL ile ilk ve son sensör değerleri arasındaki farkın güçlü bir negatif ilişki olduğu sonucuna varılmaktadır.

Bu ilişkiden çıkan bir diğer sonuç ise, yeni fark özniteliğinin tahmin modelinin aynı sensör ölçümlerini kullanmasına rağmen başlangıç noktasından değişim noktasına kadar farklı maksimum RUL seviyelerine sahip motorların ayırt edebilmesi için değerli bilgiler sağlamasıdır.

Algoritma 1'de olduğu gibi, belirli bir motorun birleştirilmiş sensör zaman serisi verilerinden fark özniteliğin oluşturulması, her bir zaman adımında yer alan ölçüm değerleri ile ilgili zaman serisinin ilk ölçüm değeri arasındaki fark alınarak gerçekleştirilir. Böylece birleştirilmiş sensör verileriyle eşit örneklem boyutu elde edilmiştir. Oluşturulan fark özniteliği, mevcut birleştirilmiş sensör verilerine eklenerek yeni girdi veri seti oluşturulmuş, sonrasında prognostik prosedür içerisindeki diğer işlem adımları uygulanmıştır.

4.1.7 Ağ yapılandırma ve hiper parametre ayarlama

Turbo fan motorlarında RUL tahmini için önerilen prognostik yaklaşım derin sinir ağları içermektedir. Sinirsel ağ tasarımında kullanılan hiperparametreler, derin sinir ağlarının tahmin performansını önemli ölçüde etkilemektedir.

En iyi hiper parametre kombinasyonunu seçmek için ızgara arama (Gong ve diğerleri, 2022; Muneer ve diğerleri, 2021; Wang ve Wu, 2021), rastgele arama (Ayodeji ve diğerleri, 2022; Wang ve Zhao, 2022) ve genetik algoritma (Sova ve diğerleri, 2023) gibi sezgisel algoritmalar kullanılmaktadır.

Bu tez çalışmasında önerilen 1D-CNN-LSTM hibrit sinirsel ağ yapısı Bölüm 3.2.7'de verilmiştir. Önerilen 1D-CNN-LSTM hibrit sinir ağı yapısı, temel 1D-CNN ve temel LSTM versiyonlarından yararlanılarak oluşturulmuş ve sonuçları temel versiyonları ile karşılaştırılmıştır. Değerlendirilen hiper parametreler ise katman sayısı, parti büyüklüğü, epok/dönem sayısı, filtre boyutu ve ağın ilk katmanındaki birim sayısıdır. Tez çalışması kapsamında, iki katmanlı sinir ağlarını tasarlamak için genel bir yaklaşım benimsenmiştir. Bu yaklaşımda, iki katmanlı sinirsel ağlarda, filtre boyutu veya ilk katmandaki birim sayısı belirli bir değerle başlar ve ikinci katmanda bu değer yarıya indirilir. Bu yaklaşım, ilgili sinirsel ağlarda kullanılan filtre boyutu ve birim sayısının düşük ve yüksek değerlerinin etkileri hakkında yararlı bir fikir vermektedir.

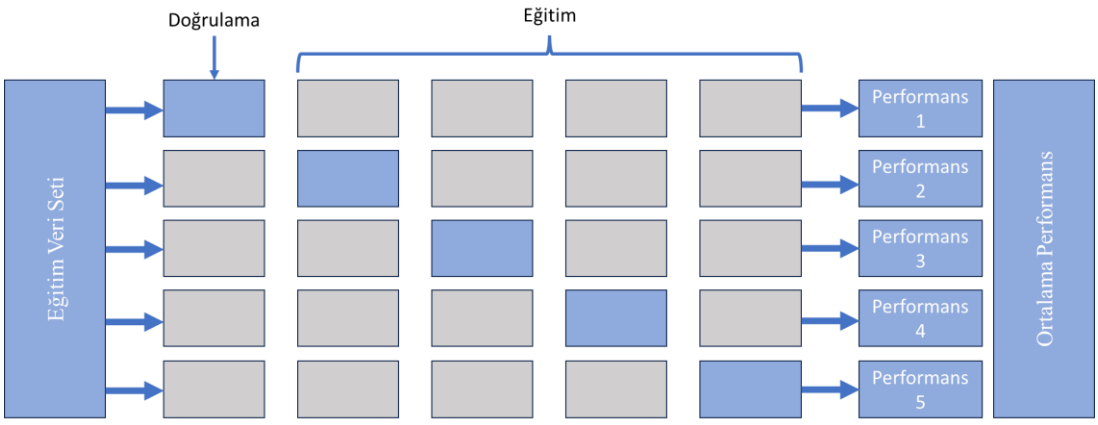
Hiper parametrelerin değer aralıkları Çizelge 4.3'te gösterilmiştir. 1D-CNN-LSTM hibrit sinirsel ağı için, katman sayısındaki "1" değeri bir 1D-CNN katmanı ve ardından bir LSTM katmanı anlamına gelmektedir. Benzer şekilde, "2" değeri ardışık iki 1D-CNN katmanı ve ardışık iki LSTM katmanı anlamına gelmektedir. Epok/dönem sayısı için, hem öğrenmenin sağlandığından emin olunacak ve aynı zamanda aşırı öğrenmeden kaçınacak değerler aralığı oluşturulmuştur. Parti büyüklüğü için değer aralıkları belirlenirken hem veri boyutunun büyüklüğü dikkate alınarak hem de hiper parametre arama uzayını kontrolsüz şekilde büyütmeye engel olacak değerlerden kaçınılmıştır. Değer aralıklarında belirlenen bu yaklaşım ile hiper parametrelerin küçük ve büyük değerleri arasında tahmin performansının değişimi hakkında bilgi sahibi olmak amaçlanmıştır.

Çizelge 4.3. RUL tahmini için kullanılan sinirsel ağ hiper parametre değer aralıkları

Hiper parametreler	Değer Aralıkları
Katman sayısı	{1, 2}
Epok/Dönem sayısı	{20, 25, 30, 40, 50, 60, 80, 100}
Parti büyüklüğü	{64, 128, 256}
İlk katmandaki filtre boyutu	{32, 64, 128, 256}
İlk katmandaki birim sayısı	{32, 64, 128, 256}

Bu tez çalışmasında, önerilen derin öğrenme modelinin optimum hiper parametre değerlerini belirlemek için ızgara arama ve k-katlı çapraz doğrulama (k-fold cross validation) yöntemi kullanılmıştır. Çapraz doğrulama, doğrulama seti seçimindeki şans faktörünün neden olduğu model değerlendirmesindeki sapmaları azaltmaktadır. Çapraz doğrulama sayesinde veri kümesindeki tüm verilerden tam olarak yararlanılır.

k-katlı çapraz doğrulama sürecinde, veri seti k adet çakışmayan katlara bölünür. $K - 1$ adet kat eğitim verisi olarak kullanılır ve kalan kat doğrulama verisi olarak kullanılır. Tüm süreç K kez döngüye girer, aslında K model eğitilir ve son K döngüsünden sonra yöntemin ortalaması alınır. Süreç, tüm hiper parametre ve bu hiper parametrelere ait değer aralıklarındaki tüm değerler için tekrarlanır ve ardından en yüksek puana sahip hiper parametre kombinasyonu seçilir. Tez çalışması kapsamında 5-katlı çapraz doğrulama yöntemi kullanılmış ve uygulanışı Şekil 4.9'da gösterilmiştir.



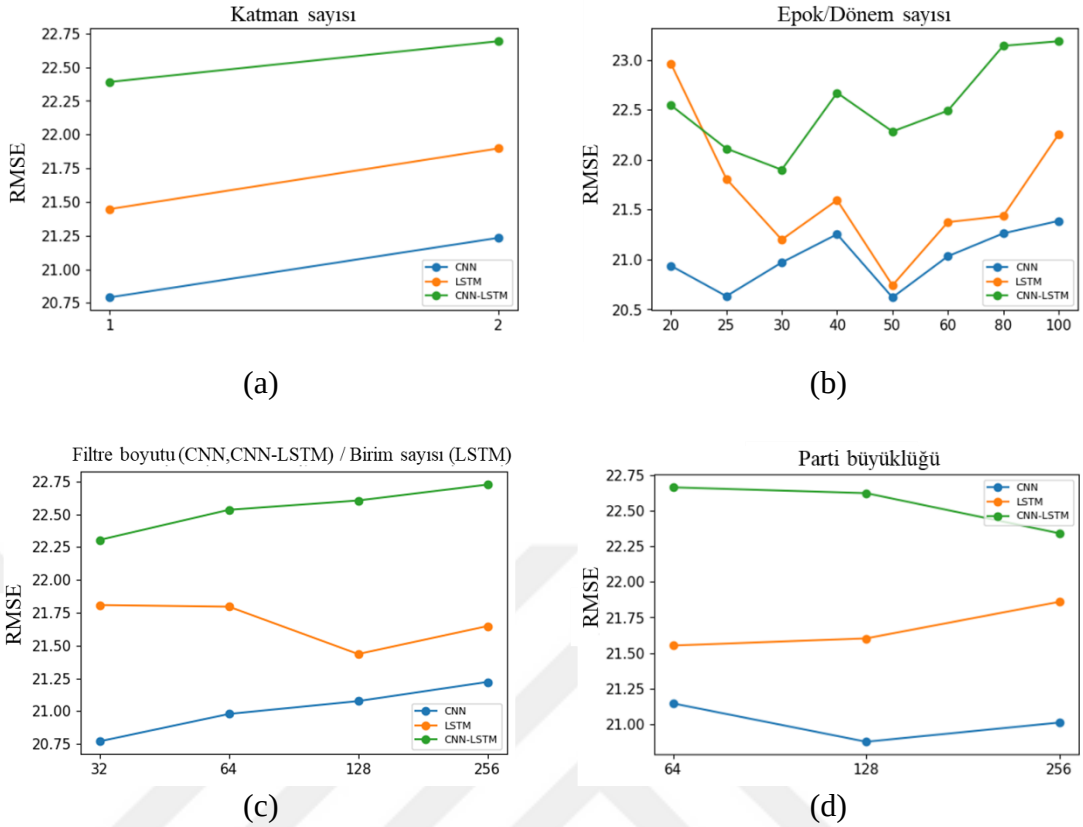
Şekil 4.9. 5-katlı çapraz doğrulama

Ağ ağırlıklarının optimizasyonu için Adam algoritması kullanılmıştır. 1D-CNN için kernel/filtre boyutu 3 olarak ayarlanmış ve havuzlama işlemleri için havuz boyutu 3 olan

maksimum havuzlama yöntemi kullanılmıştır. Çıkış katmanı hariç tüm ağ katmanlarında kullanılan aktivasyon fonksiyonları ReLU ‘dur. Tam bağlı katman sayısı ikidir ve bu iki katman için kullanılan düğüm sayısı her bir sinirsel ağ katmanı için 50 olarak ayarlanmıştır.

Deneyler Intel Core i5-8250U (1.60 GHz) CPU, 8 GB bellek ve Microsoft Windows 11 işletim sistemine sahip bir kişisel bilgisayarda gerçekleştirilmiştir. Programlama dili Python, sinir ağları oluşturmak için kullanılan TensorFlow (Abadi ve diğerleri, 2016) ve Keras (Chollet ve diğerleri, 2015) kütüphaneleri kullanılmıştır.

En iyi hiper parametre kombinasyonu ana etki grafiklerine göre belirlenmiştir. İlk olarak, her bir hiper parametre için tüm değer aralıklarını göz önünde bulundurarak bir hiper parametre uzayı oluşturulmuştur. Bu uzayda, tüm hiper parametre değerlerini içeren 192 farklı kombinasyon vardır (ilk hiper parametre için 2, ikincisi için 8, üçüncüsü için 3 ve dördüncüsü için 4 ayrı değer). Daha sonra her bir kombinasyon, her birinin genel etkilerini kapsamlı bir şekilde değerlendirmek için istatistiksel olarak bağımsız on deney olacak şekilde tekrarlanmıştır. Her bir hiper parametre değerinin ortalama performansını hesaplayan ana etki grafikleri, bir hiper parametrenin tahmin performansı üzerindeki etkisini incelemeye yardımcı olmaktadır. Şekil 3.13, temel ve hibrit ağların hiper parametreleri için ana etki grafiklerini göstermektedir. Örneğin, ağ modelinin derinliğini ve karmaşıklığını ifade eden katman sayısı parametresinin etkisi Şekil 3.13a'da gözlemlenebilir.



Şekil 4.10. Hiper parametrelere ilişkin deneysel analiz sonuçları (a) katman sayısı (b) epok/dönem sayısı

Ana etkilerin deneysel sonuçları analiz edildikten sonra, Çizelge 4.4'te gösterildiği gibi nihai ağ yapılandırması ve eğitimi için en düşük RMSE değerlerini veren hiper parametre değerleri seçilmiştir.

Çizelge 4.4. Seçilen hiper parametre değerleri

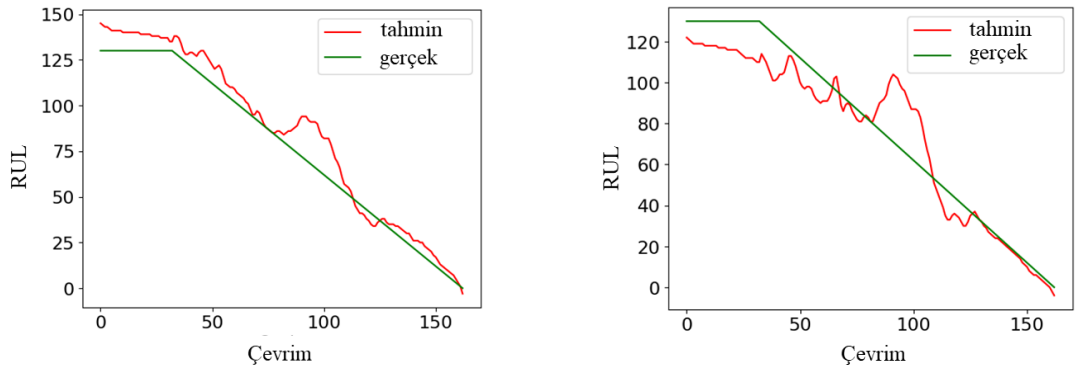
Hiper parametreler	**CNN**	**LSTM**	**1D-CNN-LSTM**
Katman sayısı	1	1	1
Epok/dönem sayısı	50	50	30
Parti büyüklüğü	128	64	256
İlk katmandaki filtre büyüklüğü	32	-	32
İlk katmandaki birim sayısı	-	128	-

4.2. Deneysel Sonuçlar ve Tartışma

Bu bölümde, turbo fan motorlarının RUL tahmini için önerilen prognostik prosedürün deneysel sonuçları sunulmaktadır. İlk olarak, çeşitli sinirsel ağ modellerin performansları RMSE ve skor fonksiyonu kullanılarak değerlendirilmiştir. PELT ve pwlf yöntemlerinin değişim noktası tespiti üzerindeki etkinliği değerlendirilmiştir. Ardından, yeni elde edilen fark temelli özniteliğin RUL tahminindeki etkisi analiz edilmiş ve bir ablasyon çalışması olarak sunulmuştur. Son olarak, literatürde her bir motora özgü hedef etiketlemesinin yapıldığı benzer çalışmalarla bir karşılaştırma yapılmıştır.

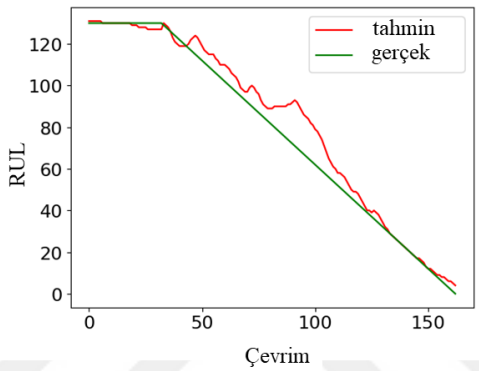
4.2.1. Farklı sinir ağı mimarileri için tahmin performansının karşılaştırması

1D-CNN-LSTM hibrit ağının tahmin sonuçları, hibrit ağı oluşturan temel 1D-CNN ve temel LSTM ağı ile ayrı ayrı karşılaştırılmıştır. Ayrıca, önerilen hibrit ağ ve temel modeller k-NN (Ramasso ve diğerleri, 2013), RF (Gong ve diğerleri, 2022) ve GBM (Siqueira ve diğerleri, 2023) gibi literatürde yaygın olarak kullanılan ve iyi bilinen geleneksel makine öğrenimi yöntemleriyle karşılaştırılmıştır. Ek olarak, en eski derin öğrenme yöntemlerinden biri olan grup veri işleme yöntemi (GMDH) (Ivakhnenko, 1971) karşılaştırma için kullanılmıştır. Rastgeleliğin etkisini hafifletmek için her deney on kez tekrarlanmış ve ortalama değer olarak raporlanmıştır. Eğitilen modeller, test motorlarının RUL değerlerini tahmin etmek için kullanılmıştır. Önerilen 1D-CNN-LSTM hibrit modelinin ve temel versiyonlarının, yani bir 1D-CNN ve LSTM ağının, eğitim setindeki aynı motor için performansları Şekil 4.11'de gösterilmektedir.



(a)

(b)



(c)

Şekil 4.11. Rastgele seçilen bir motorun eğitim sonuçları (a) 1D-CNN (b) LSTM (c) 1D-CNN-LSTM

Şekil 4.11'den, motorların arıza zamanına yaklaştığında tahmin edilen RUL ve gerçek RUL değerleri arasındaki farkların, sağlıklı dönem tahmin farklarına göre daha küçük olduğu gözlemlenmektedir. Tahmin hatalarının arızaya yaklaştıkça azalmasının nedeni, sistemin zaman geçtikçe daha fazla bozulma bilgisi biriktirmiş olmasıdır. Buna ek olarak, Şekil 4.11' 'den her bir sinir ağı modelinin motorların değişim noktasını başarılı bir şekilde tespit ettiği görülmektedir. Tahmin edilen sinyallerin değişim noktaları, gerçek PwL temelli hedef RUL etiketlemesine ait değişim noktalarıyla benzer çevrim değerinde olduğu görülmüştür.

Yedi farklı sinirsel ağ mimarisi için test verilerini kullanarak, yeni eklenen fark temelli öznitelik ile elde edilen ve bu öznitelik olmadan elde edilen RUL tahmin sonuçları Çizelge 4.5'te gösterilmektedir. RMSE ve skor fonksiyonu için en iyi performanslar kalın harflerle gösterilmiştir. Gösterilen sonuçlar tekrarlanan on deneyin ortalaması ve standart sapmasıdır. Sonuçlarda ilk olarak ilgili ağın yalnızca birleştirilmiş sensör değerleri

kullanılarak elde edilen tahmin sonuçları, hemen altında ise yeni eklenen fark özniteliğinin birleştirilmiş sensör değerleri verisine yeni bir öznitelik olarak eklenerek elde edilen tahmin sonuçları yer almaktadır.

Çizelge 4.5. Test veri seti üzerinde fark temelli özniteliğin kullanıldığı ve kullanılmadığı sinirsel ağlarda RUL tahmin performanslarının karşılaştırılması

Metotlar	**RMSE**	**Skor**
k-NN (fark özniteliği yok)	19,2 ± 0,4	1180,6 ± 360,7
k-NN (fark özniteliği var)	20,9 ± 0,2	825,2 ± 22,8
RF (fark özniteliği yok)	21,5 ± 0,2	2447,9 ± 383,2
RF (fark özniteliği var)	19,5 ± 0,2	830,2 ± 105,2
GBM (fark özniteliği yok)	19,2 ± 0,3	1454,7 ± 395,6
GBM (fark özniteliği var)	18,3 ± 0,5	714,2 ± 195,9
GMDH (fark özniteliği yok)	18,0 ± 0,2	651,5 ± 90,5
GMDH (fark özniteliği var)	17,7 ± 0,2	542,1 ± 70,4
LSTM (fark özniteliği yok)	17,8 ± 0,7	2476,3 ± 1607,1
LSTM (fark özniteliği var)	17,0 ± 1,3	1176,5 ± 1368,6
1D-CNN (fark özniteliği yok)	17,2 ± 0,2	716,1 ± 129,8
1D-CNN (fark özniteliği var)	**15,5 ± 0,5**	498,9 ± 170
1D-CNN-LSTM (fark özniteliği yok)	19,1 ± 2,1	1680,9 ± 1284,1
1D-CNN-LSTM (fark özniteliği var) (Önerilen)	16,1 ± 0,5	**437,2 ± 126,4**

Önerilen yeni fark temelli özniteliğe sahip 1D-CNN-LSTM hibrit ağının, skor fonksiyonu açısından fark temelli özniteliğe sahip temel 1D-CNN ve temel LSTM ağlarının test verisi kullanılarak elde edilen RUL tahmin performans değerleri sırasıyla 437,2, 498,9 ve 1176,5'tir. Fark temelli özniteliğe sahip 1D-CNN-LSTM modelinin ortalama puanı, fark temelli özniteliğin eklenmiş olduğu 1D-CNN modelinden %14, fark temelli özniteliğin eklenmiş olduğu LSTM modelinden ise %169 daha iyi sonuç vermiştir. Ayrıca, 1D-CNN-LSTM modelinin standart sapması 126,4, 1D-CNN modelininki 170 ve LSTM modelininki 1368,6'dır. Önerilen 1D-CNN-LSTM modelinin standart sapması temel modeller arasında en küçük olanıdır ve daha sağlam tahmin sonuçları sağlar. Ayrıca 1D-CNN, her iki durum için de 1D-CNN-LSTM hibrit ağındaki sağlam özellik çıkarma kabiliyeti sayesinde LSTM sinirsel ağına yararlı bilgiler sağlayarak ağın performansını artırmıştır.

Tahmin sonuçları, derin öğrenme yöntemlerinin öncülerinden biri olan GMDH ile karşılaştırıldığında, önerilen hibrit 1D-CNN-LSTM ağı, GMDH'nin 542,1 puanını geride bırakarak üstün performans göstermiş ve RMSE açısından da üstünlük sağlamıştır.

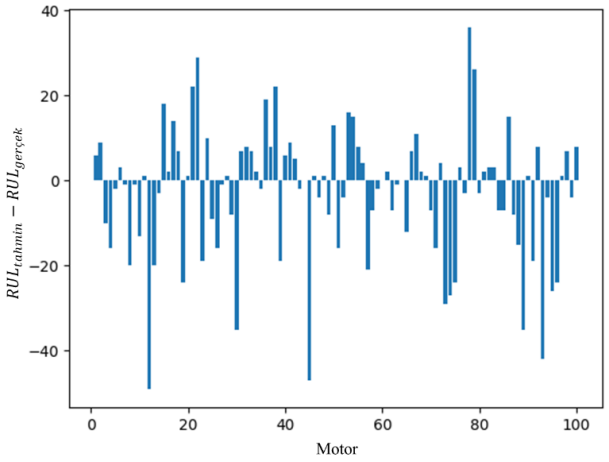
Turbo fan motorlarda RUL tahmin probleminin çözümü için derin öğrenme yöntemleri ile geleneksel makine öğrenmesi yöntemleri karşılaştırıldığında, nispeten daha düşük performans sergileyen LSTM ağına kıyasla 1D-CNN-LSTM hibrit ağının performansının oldukça güçlü olduğu gözlemlenmiştir.

Derin öğrenme yöntemlerinin, kendi aralarındaki performans değerlendirmesinde MAPE metriği de kullanılmış ve yeni eklenen fark özniteliğinin kullanıldığı modeller üzerinde yapılan deneyler sonucunda elde edilen sonuçlar Çizelge 4.6'da gösterilmiştir.

Çizelge 4.6. Derin öğrenme yöntemlerinde MAPE karşılaştırması

Metot	**MAPE**
GMDH	25,1 ± 0,9
LSTM	20,7 ± 2,2
1D-CNN	20,4 ± 0.7
1D-CNN-LSTM (Önerilen)	**19,3 ± 1,1**

FD001 test veri setinde her bir motorun sensör değerlerinin kesildiği son zaman adımındaki gerçek RUL değerleri ve eğitilmiş 1D-CNN-LSTM sinirsel ağında tahmin edilen RUL değerleri arasındaki fark Şekil 4.12'de gösterilmektedir. Negatif değerler zamanından önceki erken tahminleri gösterirken, pozitif değerler ise geç tahminleri göstermektedir.



Şekil 4.12. Test veri setindeki gerçek ve tahmin edilen RUL değerleri arasındaki fark

4.2.2. Değişim noktası tespiti yöntemlerinin değerlendirilmesi

Tez çalışmasının en önemli motivasyonlarından bir tanesi, turbo fan motorlarında RUL tahmin problemini değişim noktası tespiti temelli hedef RUL etiketleme yaklaşımıyla gerçek dünya problemine yaklaştırmaktır. Bu sebeple değişim noktası tespiti, RUL tahmini için motora özgü hedef etiketlemede çok önemlidir. Önerilen pwlf tabanlı değişim noktası tespit yönteminin etkinliğini göstermek için, değişim noktası tespiti için yaygın olarak bilinen PELT algoritması ve pwlf' nin çeşitli parametre ayarlarını kullanarak çeşitli tahmin sonuçları elde edilmiştir, Çizelge 4.7'de gösterilmiştir.

Çizelge 4.7. Değişim noktası tespit yöntemlerinin karşılaştırılması

Metot	RMSE	Skor
PELT	35,8 ± 1,6	3576,5 ± 726,0
pwlf (2 adet doğru)	34,1 ± 1,1	3092,5 ± 395,7
pwlf (3 adet doğru)	17,0 ± 1,0	503,7 ± 118,6
pwlf (4 adet doğru)	16,4 ± 0,6	522,2 ± 128,8
pwlf (5 adet doğru) (Önerilen)	**16,1 ± 0,4**	**437,2 ± 119,9**

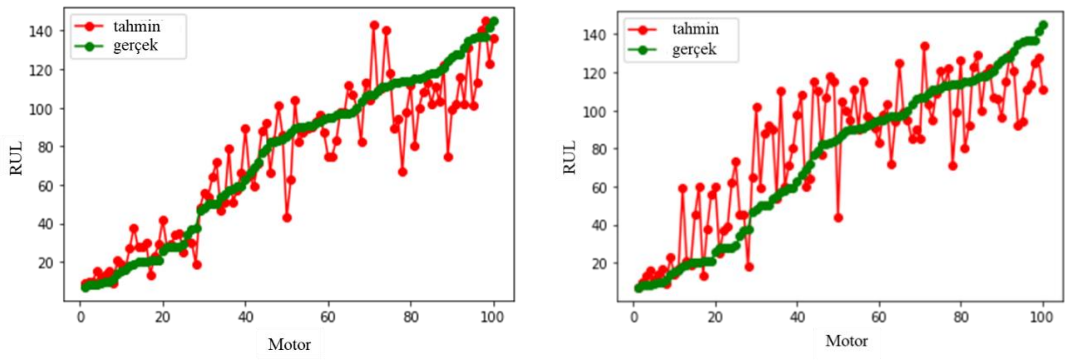
Değişim noktası tespit yöntemlerinin değerlendirilmesinde, tez çalışması kapsamında önerilen fark temelli özniteliğin veri setine dahil edildiği veriler girdi olarak kullanılmış ve sinirsel ağ olarak da yine önerilen 1D-CNN-LSTM hibrit ağı kullanılmıştır. Her bir yöntem için on tekrar gerçekleştirilmiş ve sonuçlar ilgili ortalama ve standart sapma değerleriyle birlikte sunulmuştur. pwlf yönteminde, değişim noktası sayısı veya elde edilmek istenen doğru sayısı parametresine ait değerler 2 ile 5 arasında değiştirilmiştir. Kullanılan her bir parametre ile elde edilen tüm sonuçlar, PELT yöntemine kıyasla hem RMSE hem de skor metrikleri açısından daha üstün performans sergilemiştir. Ayrıca, çizgi-segment parametresini ayarlarken pwlf yöntemini incelediğimizde, parametre değerindeki bir artış tahmin hatalarının azalmasına ve tahmin performansının iyileşmesine neden olmuştur. Değişim noktası tespiti için önerilen ve 5 doğrulu konfigürasyonu kapsayan yaklaşım, RUL tahmini için motora özgü hedef etiketlemede önemli bir gelişme sağlamıştır.

4.2.3. Önerilen fark temelli öznitelik oluşturma yaklaşımının değerlendirilmesi

Önerilen fark temelli öznitelik oluşturma yaklaşımın etkinliğini değerlendirmek amacıyla, bu çalışmada yukarıda bahsedilen sinir ağları üzerinde bir ablasyon çalışması

gerçekleştirilmiştir. İlk olarak, RUL tahmini için yalnızca birleştirilmiş sensör verilerini girdi olarak kullanan sinirsel ağlar kullanılmıştır. Daha sonra, birleştirilmiş sensör verilerine fark temelli yeni öznitelik eklenmiş ve RUL tahmini gerçekleştirilmiştir. Ablasyon çalışmasının sonuçları da Çizelge 4.5'te bulunabilir.

Sonuçlar, birleştirilmiş sensör verilerine fark temelli öznitelik eklendiğinde tüm ağların bu özniteliğin kullanılmadığı sinirsel ağlardan daha iyi performans gösterdiğini ortaya koymakta ve özellik oluşturma yaklaşımının etkinliğini vurgulamaktadır. Ayrıca, 1D-CNN-LSTM'nin temel 1D-CNN, temel LSTM ağı ve diğer ilgili ağlara kıyasla, RMSE ve skor fonksiyonu açısından ek öznitelikler olsun ya da olmasın, üstün performans sergilediği sonucuna varılabilir. Önerilen 1D-CNN-LSTM hibrit sinirsel ağının gerçek RUL değerlerine kıyasla tahmin edilen sonuçları, veri setindeki tüm motorlar için fark temelli öznitelikli veya fark temelli öznitelik olmadan, Şekil 4.3'te gösterilmektedir. Şekil 4.3b'de görüldüğü gibi, yeni eklenen fark temelli öznitelik ile gerçek ve tahmin sonuçları arasındaki farklar azalmıştır. Motora özgü değişim noktası temelli hedef RUL etiketleme yaklaşımı ile zorlaşan RUL tahmin probleminde, motorların sağlıklı dönemde ayırt edici özelliklerinin olmaması nedeniyle Şekil 4.13a'da normalden erken yapılan tahminler, yeni fark temelli özniteliğin veri setine eklenmesiyle erken dönem tahminler gerçek değerlere yaklaşmıştır. Yeni eklenen fark temelli öznitelik ile yapılan RUL tahmininin, yalnızca birleştirilmiş sensör sinyallerinin kullanılarak yapılan RUL tahmininden çok daha iyi performans sergilediği görülmüştür.



(a) (b)

Şekil 4.13. Test veri setindeki 100 adet motor için RUL tahminleri (artan RUL'a göre sıralanmıştır) (a) fark özniteliği yok (b) fark özniteliği var

4.2.4. İlgili çalışmalarla karşılaştırma

Turbo fan veri seti, prognostik araştırmalarda güncelliğini koruyan popüler bir genel veri setidir. Bu tez çalışmasında, değişim noktası tespit tabanlı hedef RUL etiketleme ve öğrenmeye yardımcı olan yeni fark temelli öznitelik oluşturulmasını içeren bir RUL tahmin yaklaşımı önermektedir. Önerilen yöntemin prognostik performansı, aynı veri kümesini ve benzer prognostik yaklaşımları kullanan çalışmalarla birlikte Çizelge 4.8'de verilmiştir.

Çizelge 4.8. Önerilen yöntem ile C-MAPSS veri setini içeren ilgili makalelerin performans karşılaştırması

Yazarlar	Yöntem	RMSE	Skor	Veri Seti
Huang vd. (2020)	Bayes Sinirsel Ağı (BNN)	17,92	N/A	Test
Aydemir ve Acar (2020)	LSTM	17,15	392	Test
Miao vd. (2019)	Çift-Görevli LSTM	12,29	N/A	Eğitim
Önerilen yaklaşım	1D-CNN-LSTM (öznitelik ekleme)	16,1	437,2	Test

Çizelge 4.8'deki çalışmaların bir kısmı, LSTM ve CUMSUM gibi çeşitli metodolojilerle belirlenen motora özgü RUL etiketlerini kullanmaktadır. Ayrıca, motora özgü RUL etiketlerini kullanan çalışmaların çoğu, daha önce de belirtildiği gibi, test veri setini kullanmak yerine eğitim veri setinin belirli bir kısmını test verisi olarak kabul edip tahminler yapmaktadır. Çizelge 4.8'de yer alan karşılaştırmada "Test Verisi" sütunu, test aşamasında kullanılan veri kümesinin türünü ifade etmektedir. "Test" test için orijinal test veri setinin kullanıldığını gösterirken, "Eğitim" eğitim veri setinin belirli bir kısmının test için kullanıldığını göstermektedir.

FD001'in test veri setinde sensör verileri keyfi bir çevrim değerinde sonlandırılmıştır ve bu nedenle motora özgü hedef RUL etiketlemeyi temel alan yalnızca birkaç çalışma RUL tahmininde orijinal test kümesini kullanmıştır. Miao ve diğerlerinin (2019) elde ettiği RMSE değeri en düşüktür çünkü başlangıçtan arıza zamanına kadar tüm sensör değerlerini içeren eğitim veri kümesinin bir kısmı test veri kümesi olarak kullanılmıştır. Aydemir ve Acar'ın (2020) yöntemi, tez çalışması kapsamında önerilen prognostik prosedüre göre daha düşük bir skor değeri elde etmiştir. Ancak, skor fonksiyonu asimetrik bir fonksiyondur ve geç tahminlere erken tahminlerden daha fazla ceza puanı vererek hesaplanmaktadır. Hem skor fonksiyonunun asimetrik yapısı ve RMSE değerleri dikkate

alındığında önerilen prognostik prosedürün ilgili çalışmalar içerisinde performansının yüksek olduğu görülmektedir.

5. SONUÇ

Turbo fan motorlar için RUL değerinin etkili bir şekilde tahmin edilmesi, optimum performansın sağlanması ve bakım maliyetlerinin en aza indirilmesi için kritik öneme sahiptir. Bu tez çalışması, değişim noktası temelli hedef etiketlemeyi, özellik mühendisliği sürecini ve 1D-CNN-LSTM tabanlı bir hibrit ağı ele alan bir prognostik prosedür önermektedir. Önerilen yaklaşım, ham sensör verilerinden uzamsal bilgileri çıkarmak için 1D-CNN mimarisini kullanırken, çıkarılan özelliklerden zamansal bilgileri ortaya çıkarmak için LSTM kullanılmıştır. Veri kalitesini ve güvenilirliğini artırmak için özellik seçimi, filtreleme ve ölçekleme kullanılmıştır. Ayrıca, bu yöntemler derin öğrenme modellerinin verileri kullanmasını ve yorumlamasını kolaylaştırmıştır. Buna ek olarak, boyut azaltma ve özellik oluşturma gibi özellik mühendisliği yaklaşımları, yalnızca mevcut verilerin yorumlanmasını kolaylaştırmakla kalmamış, aynı zamanda verilerin verimliliğini artırmış ve tahmin modelinin öğrenilmesini kolaylaştıran yeni özelliklerin oluşturulmasını sağlamıştır. Önerilen prognostik yaklaşım, hibrit sinir ağının pratik ön işleme adımlarıyla birleştirildiğinde daha doğru RUL tahminleri ürettiğini göstermiştir. Turbo fan motorların çalışma ömrünü etiketlemek için, motorların çalışma ömrünü kararlı sağlıklı aşama ve doğrusal bozulma aşaması olmak üzere iki aşamaya ayıran PwL hedef etiketleme yöntemi kullanılmıştır. Sensör ölçümlerinin ana özelliklerinin ve kırılma noktalarının daha iyi temsil edilmesi için boyut indirgemeden yararlanılmıştır. Motora özel hedef RUL etiketlemesi için bozulmanın başlangıç noktasını belirlemek üzere bir değişim noktası tespit yöntemi kullanılmıştır. Her bir motora özgü maksimum RUL değerinin kullanılması, problemi gerçek hayat problemine yaklaştırmakla birlikte yetersiz bozulma bilgisi nedeniyle RUL tahmini zorlaşmıştır. Buna çözüm olarak, erken aşamada daha fazla bozulma bilgisi sağlamak için ilk sensör ölçümlerini kullanarak mevcut veri kümesinden yeni bir öznitelik oluşturulmuştur.

Önerilen metodoloji, motora özgü hedef RUL etiketlerini ve gerçek test veri setini kullanan çalışmalara kıyasla daha iyi tahmin sonuçları sağlamaktadır. Turbo fan motorlarda RUL tahmini için önerilen prognostik prosedür esasen bir özellik mühendisliği tekniğinin, özellikle de öznitelik oluşturma adımının ve 1D-CNN-LSTM ağ modelinin etkinliğini göstermiştir. Önerilen hibrit ağ, en iyi sonuçları elde etmek için k-kat çapraz doğrulama kullanılarak çoklu hiper parametre kombinasyonları üzerinde test

edilmiştir. Hibrit model, 1D-CNN ve LSTM ağları ile ayrı ayrı karşılaştırılmış ve bulgularımız CNN özellik çıkarma kabiliyetinin LSTM ağının performansını önemli ölçüde artırdığını göstermiştir. Elde edilen sonuçlar, öznitelik oluşturma yoluyla yeni oluşturulan "fark" özniteliğinin etkinliğine dair kanıt sağlamaktadır. Ayrıca, hiper parametre optimizasyon çalışması, öznitelik mühendisliği süreçleri bağlamında daha derin ve daha karmaşık ağ modellerine olan ihtiyacın azaldığını ortaya koymuştur. RUL tahmini ile ilgili uzun yıllardır süregelen çalışmalar, yapay zekâ yöntemlerinin ilerlemesiyle daha da canlanmıştır ve ilgi çekmektedir. Hem turbo fan motorlar hem de diğer uygulama alanlarındaki RUL problemiyle ilgili eğilim göz önüne alındığında, bu tez çalışması çağdaş gereksinimlerle uyumlu bir çalışmadır. Bulgular, veri ön işlemenin tahmin performansı üzerindeki etkisini kanıtlamakta ve ön işlemenin karmaşık ağ yapılarına olan bağımlılığın azaldığını ortaya koymaktadır. Gelecekteki çalışmalar için, motora özgü RUL etiketleme, benzerlik tabanlı yöntemler ve sinir ağlarını birleştirerek bozulmanın erken aşamasında daha yüksek doğruluk elde etmeyi hedefliyoruz. Ayrıca PwL etiketlerinin değişim noktasını belirlemek için daha sağlam yaklaşımlar benimsemeyi hedefliyoruz. Genel olarak, önerdiğimiz yaklaşım umut verici sonuçlar sağlamakta ve turbo fan motorların prognostiği ve sağlık yönetimi konusunda daha fazla araştırma için yollar açmaktadır.

KAYNAKLAR

Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., … Research, G. (2016). *TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems*. Retrieved from https://arxiv.org/abs/1603.04467v2

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. https://doi.org/10.1016/J.COMPIND.2019.02.004

Al Bataineh, A., Mairaj, A., & Kaur, D. (2020). Autoencoder based Semi-Supervised Anomaly Detection in Turbofan Engines. *International Journal of Advanced Computer Science and Applications*, *11*(11), 41–47. https://doi.org/10.14569/IJACSA.2020.0111105

Aminikhanghahi, S., & Cook, D. J. (2017). A survey of methods for time series change point detection. *Knowledge and Information Systems*, *51*(2), 339–367. https://doi.org/10.1007/s10115-016-0987-z

Aremu, O. O., Hyland-Wood, D., & McAree, P. R. (2020). A machine learning approach to circumventing the curse of dimensionality in discontinuous time series machine data. *Reliability Engineering and System Safety*, *195*(October 2019), 106706. https://doi.org/10.1016/j.ress.2019.106706

Aydemir, G., & Acar, B. (2020). Anomaly monitoring improves remaining useful life estimation of industrial machinery. *Journal of Manufacturing Systems*, *56*, 463–469. https://doi.org/10.1016/J.JMSY.2020.06.014

Ayodeji, A., Wang, Z., Wang, W., Qin, W., Yang, C., Xu, S., & Liu, X. (2022). Causal augmented ConvNet: A temporal memory dilated convolution model for long-sequence time series prediction. *ISA Transactions*, *123*(xxxx), 200–217. https://doi.org/10.1016/j.isatra.2021.05.026

Bae, J., & Xi, Z. (2022). Learning of physical health timestep using the LSTM network for remaining useful life estimation. *Reliability Engineering & System Safety*, *226*, 108717. https://doi.org/10.1016/J.RESS.2022.108717

Baptista, M. L., Henriques, E. M. P., & Goebel, K. (2021). More effective prognostics with elbow point detection and deep learning. *Mechanical Systems and Signal Processing*, *146*, 106987. https://doi.org/10.1016/J.YMSSP.2020.106987

Bektas, O., Jones, J. A., Sankararaman, S., Roychoudhury, I., & Goebel, K. (2019). A neural network filtering approach for similarity-based remaining useful life estimation. *International Journal of Advanced Manufacturing Technology*, *101*(1–4), 87–103. https://doi.org/10.1007/s00170-018-2874-0

Borgi, T., Hidri, A., Neef, B., & Naceur, M. S. (2017). Data analytics for predictive maintenance of industrial robots. *Proceedings of International Conference on Advanced Systems and Electric Technologies, IC_ASET 2017*, 412–417. https://doi.org/10.1109/ASET.2017.7983729

Chen, J., Chen, D., & Liu, G. (2021). Using temporal convolution network for remaining useful lifetime prediction. *Engineering Reports*, *3*(3), 1–17. https://doi.org/10.1002/eng2.12305

Chen, Z., Wu, M., Zhao, R., Guretno, F., Yan, R., & Li, X. (2021). Machine Remaining Useful Life Prediction via an Attention-Based Deep Learning Approach. *IEEE Transactions on Industrial Electronics*, *68*(3), 2521–2531. https://doi.org/10.1109/TIE.2020.2972443

De-La-bandera, I., Palacios, D., Mendoza, J., & Barco, R. (2020). Feature extraction for dimensionality reduction in cellular networks performance analysis. *Sensors (Switzerland)*, *20*(23), 1–10. https://doi.org/10.3390/s20236944

de Cheveigné, A., & Nelken, I. (2019). Filters: When, Why, and How (Not) to Use Them. *Neuron*, *102*(2), 280–293. https://doi.org/10.1016/j.neuron.2019.02.039

De Ryck, T., De Vos, M., & Bertrand, A. (2021). Change Point Detection in Time Series Data Using Autoencoders with a Time-Invariant Representation. *IEEE Transactions on Signal Processing*, *69*, 3513–3524. https://doi.org/10.1109/TSP.2021.3087031

Ellefsen, A. L., Ushakov, S., Aesoy, V., & Zhang, H. (2019). Validation of Data-Driven Labeling Approaches Using a Novel Deep Network Structure for Remaining Useful Life Predictions. *IEEE Access*, *7*, 71563–71575. https://doi.org/10.1109/ACCESS.2019.2920297

Geitner, F. K., & Bloch, H. P. (2012). Machinery Troubleshooting. *Machinery Failure Analysis and Troubleshooting*, 295–390. https://doi.org/10.1016/B978-0-12-386045-3.00004-0

Giantomassi, A., Ferracuti, F., Benini, A., Ippoliti, G., Longhi, S., & Petrucci, A. (2012). Hidden Markov Model for Health Estimation and Prognosis of Turbofan Engines. *Proceedings of the ASME Design Engineering Technical Conference*, *3*(PARTS A AND B), 681–689. https://doi.org/10.1115/DETC2011-48174

Gong, R., Li, J., & Wang, C. (2022). Remaining Useful Life Prediction Based on Multisensor Fusion and Attention TCN-BiGRU Model. *IEEE Sensors Journal*, *22*(21), 21101–21110. https://doi.org/10.1109/JSEN.2022.3208753

Gouriveau, R., Medjaher, K., & Zerhouni, N. (2016). PHM and Predictive Maintenance. *From Prognostics and Health Systems Management to Predictive Maintenance 1*, 1–13. https://doi.org/10.1002/9781119371052.ch1

Gupta, A., Masampally, V. S., Jadhav, V., Deodhar, A., & Runkana, V. (2021). Supervised Operational Change Point Detection using Ensemble Long-Short Term Memory in a Multicomponent Industrial System. *SAMI 2021 - IEEE 19th World Symposium on Applied Machine Intelligence and Informatics, Proceedings*, 135–141. https://doi.org/10.1109/SAMI50585.2021.9378683

Heimes, F. O. (2008). Recurrent neural networks for remaining useful life estimation. *2008 International Conference on Prognostics and Health Management, PHM 2008*. https://doi.org/10.1109/PHM.2008.4711422

Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, *9*(8), 1735–1780. https://doi.org/10.1162/NECO.1997.9.8.1735

Hong, C. W., Lee, K., Ko, M. S., Kim, J. K., Oh, K., & Hur, K. (2020). Multivariate time series forecasting for remaining useful life of turbofan engine using deep-stacked neural network and correlation analysis. *Proceedings - 2020 IEEE International Conference on Big Data and Smart Computing, BigComp 2020*, 63–70. https://doi.org/10.1109/BigComp48618.2020.00-98

Huang, C. G., Huang, H. Z., Peng, W., & Huang, T. (2019). Improved trajectory similarity-based approach for turbofan engine prognostics. *Journal of Mechanical Science and Technology*, *33*(10), 4877–4890. https://doi.org/10.1007/s12206-019-0928-3

Huang, D., Bai, R., Zhao, S., Wen, P., Wang, S., & Chen, S. (2020). Bayesian neural network based method of remaining useful life prediction and uncertainty quantification for aircraft engine. *Proceedings of the Annual Conference of the Prognostics and Health Management Society, PHM*, *2020-June*.

https://doi.org/10.1109/ICPHM49022.2020.9187044
Ivakhnenko, A. G. (1971). Polynomial Theory of Complex Systems. *IEEE Transactions on Systems, Man and Cybernetics*, *1*(4), 364–378. https://doi.org/10.1109/TSMC.1971.4308320
Jackson, B., Scargle, J. D., Barnes, D., Arabhi, S., Alt, A., Gioumousis, P., … Tsai, T. T. (2005). An algorithm for optimal partitioning of data on an interval. *IEEE Signal Processing Letters*, *12*(2), 105–108. https://doi.org/10.1109/LSP.2001.838216
Jekel, C. F., & Venter, G. (2019). *PieceWise Linear Fitting : A Python Library for Fitting 1D Continuous Piecewise Linear Functions*. (March), 1–15. Retrieved from https://github.com/cjekel/piecewise_linear_fit_py
Jimenez-Cortadi, A., Irigoien, I., Boto, F., Sierra, B., & Rodriguez, G. (2020). Predictive maintenance on the machining process and machine tool. *Applied Sciences (Switzerland)*, *10*(1). https://doi.org/10.3390/app10010224
Kawahara, Y., & Sugiyama, M. (2009). Change-point detection in time-series data by direct density-ratio estimation. *Society for Industrial and Applied Mathematics - 9th SIAM International Conference on Data Mining 2009, Proceedings in Applied Mathematics*, *1*, 385–396. https://doi.org/10.1137/1.9781611972795.34
Keras: Deep Learning for humans. (n.d.). Retrieved December 11, 2023, from https://keras.io/
Khelif, R., Chebel-Morello, B., Malinowski, S., Laajili, E., Fnaiech, F., & Zerhouni, N. (2017). Direct Remaining Useful Life Estimation Based on Support Vector Regression. *IEEE Transactions on Industrial Electronics*, *64*(3), 2276–2285. https://doi.org/10.1109/TIE.2016.2623260
Kürşat İnce. (2023). *Joint Autoencoder-Based Predictive Maintenance Methods for Industrial Machinery*. Gebze Teknik Üniversitesi.
Le Son, K., Fouladirad, M., & Barros, A. (2016). Remaining useful lifetime estimation and noisy gamma deterioration process. *Reliability Engineering & System Safety*, *149*, 76–87. https://doi.org/10.1016/J.RESS.2015.12.016
Le Son, K., Fouladirad, M., Barros, A., Levrat, E., & Iung, B. (2013). Remaining useful life estimation based on stochastic deterioration models: A comparative study. *Reliability Engineering and System Safety*, Vol. 112, pp. 165–175. https://doi.org/10.1016/j.ress.2012.11.022
Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. https://doi.org/10.1038/nature14539
Lee, J., Kao, H. A., & Yang, S. (2014). Service Innovation and Smart Analytics for Industry 4.0 and Big Data Environment. *Procedia CIRP*, *16*, 3–8. https://doi.org/10.1016/J.PROCIR.2014.02.001
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*(3), 1314–1326. https://doi.org/10.1109/TR.2016.2570568
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. https://doi.org/10.1016/j.ymssp.2017.11.016
Li, Han, Zhao, W., Zhang, Y., & Zio, E. (2020). Remaining useful life prediction using multi-scale deep convolutional neural network. *Applied Soft Computing*, *89*, 106113. https://doi.org/10.1016/J.ASOC.2020.106113
Li, Hongmei, Huang, J., & Ji, S. (2019). Bearing fault diagnosis with a feature fusion method based on an ensemble convolutional neural network and deep neural

network. *Sensors (Switzerland)*, *19*(9). https://doi.org/10.3390/s19092034
Li, X., Ding, Q., & Sun, J. Q. (2018). Remaining useful life estimation in prognostics using deep convolution neural networks. *Reliability Engineering and System Safety*, *172*(October 2017), 1–11. https://doi.org/10.1016/j.ress.2017.11.021
Liao, L. (2014). Discovering prognostic features using genetic programming in remaining useful life prediction. *IEEE Transactions on Industrial Electronics*, *61*(5), 2464–2472. https://doi.org/10.1109/TIE.2013.2270212
Liu, Huan. (2018). Feature Engineering for Machine Learning and Data Analytics. In *Feature Engineering for Machine Learning and Data Analytics*. https://doi.org/10.1201/9781315181080
Liu, Hui, Liu, Z., Jia, W., & Lin, X. (2021). Remaining Useful Life Prediction Using a Novel Feature-Attention-Based End-to-End Approach. *IEEE Transactions on Industrial Informatics*, *17*(2), 1197–1207. https://doi.org/10.1109/TII.2020.2983760
Liu, R., Yang, B., & Hauptmann, A. G. (2020). Simultaneous bearing fault recognition and remaining useful life prediction using joint-loss convolutional neural network. *IEEE Transactions on Industrial Informatics*, *16*(1), 87–96. https://doi.org/10.1109/TII.2019.2915536
Malhi, A., Yan, R., & Gao, R. X. (2011). Prognosis of defect propagation based on recurrent neural networks. *IEEE Transactions on Instrumentation and Measurement*, *60*(3), 703–711. https://doi.org/10.1109/TIM.2010.2078296
Martin, K. F. (1994). A review by discussion of condition monitoring and fault diagnosis in machine tools. *International Journal of Machine Tools and Manufacture*, *34*(4), 527–551. https://doi.org/10.1016/0890-6955(94)90083-3
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*(9), 5023–5032. https://doi.org/10.1109/tii.2019.2900295
Miao, J., & Niu, L. (2016). A Survey on Feature Selection. *Procedia Computer Science*, *91*, 919–926. https://doi.org/10.1016/j.procs.2016.07.111
Muneer, A., Taib, S. M., Fati, S. M., & Alhussian, H. (2021). Deep-learning based prognosis approach for remaining useful life prediction of turbofan engine. *Symmetry*, *13*(10). https://doi.org/10.3390/sym13101861
Muneer, A., Taib, S. M., Naseer, S., Ali, R. F., & Aziz, I. A. (2021). Data-driven deep learning-based attention mechanism for remaining useful life prediction: Case study application to turbofan engine analysis. *Electronics (Switzerland)*, *10*(20). https://doi.org/10.3390/electronics10202453
NASA Prognostics Center of Excellence. (n.d.). Data Repository. Retrieved November 13, 2023, from https://www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository/
Peng, C., Chen, Y., Chen, Q., Tang, Z., Li, L., & Gui, W. (2021). A remaining useful life prognosis of turbofan engine using temporal and spatial feature fusion. *Sensors (Switzerland)*, *21*(2), 1–21. https://doi.org/10.3390/s21020418
Peng, C., Wu, J., Tang, Z., Yuan, X., & Li, C. (2022). *A Spatio-Temporal Attention Mechanism Based Approach for Remaining Useful Life Prediction of Turbofan Engine*. https://doi.org/10.1155/2022/9707940
Peng, C., Wu, J., Wang, Q., Gui, W., & Tang, Z. (2022). Remaining Useful Life Prediction Using Dual-Channel LSTM with Time Feature and Its Difference.

Entropy, *24*(12). https://doi.org/10.3390/e24121818

PHM 2008 Challenge | NASA Open Data Portal. (n.d.). Retrieved December 3, 2023, from https://data.nasa.gov/Raw-Data/PHM-2008-Challenge/nk8v-ckry

Ragab, A., Yacout, S., Ouali, M. S., & Osman, H. (2017). Pattern-based prognostic methodology for condition-based maintenance using selected and weighted survival curves. *Quality and Reliability Engineering International*, *33*(8), 1753–1772. https://doi.org/10.1002/qre.2142

Ramasso, E., Rombaut, M., & Zerhouni, N. (2013). Joint prediction of continuous and discrete states in time-series based on belief functions. *IEEE Transactions on Cybernetics*, *43*(1), 37–50. https://doi.org/10.1109/TSMCB.2012.2198882

Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Neural Networks*, *61*, 85–117. https://doi.org/10.1016/j.neunet.2014.09.003

Shi, Z., & Chehade, A. (2021). A dual-LSTM framework combining change point detection and remaining useful life prediction. *Reliability Engineering & System Safety*, *205*, 107257. https://doi.org/10.1016/J.RESS.2020.107257

Si, X. S., Wang, W., Hu, C. H., & Zhou, D. H. (2011). Remaining useful life estimation - A review on the statistical data driven approaches. *European Journal of Operational Research*, *213*(1), 1–14. https://doi.org/10.1016/j.ejor.2010.11.018

Sikorska, J. Z., Hodkiewicz, M., & Ma, L. (2011). Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing*, *25*(5), 1803–1836. https://doi.org/10.1016/J.YMSSP.2010.11.018

Siqueira, H. V., Corrêa, F. C., Alves, T. A., Nair, P., Vakharia, V., Borade, H., … Wankhede, V. (2023). Predicting Li-Ion Battery Remaining Useful Life: An XDFM-Driven Approach with Explainable AI. *Energies 2023, Vol. 16, Page 5725*, *16*(15), 5725. https://doi.org/10.3390/EN16155725

Song, Y., Shi, G., Chen, L., Huang, X., & Xia, T. (2018). Remaining Useful Life Prediction of Turbofan Engine Using Hybrid Model Based on Autoencoder and Bidirectional Long Short-Term Memory. *Journal of Shanghai Jiaotong University (Science)*, *23*, 85–94. https://doi.org/10.1007/s12204-018-2027-5

Sova, J., Kolar, P., Burian, D., & Vozabal, P. (2023). Remaining Useful Life Estimation of Spindle Bearing Based on Bearing Load Calculation and Off-Line Condition Monitoring. *Machines*, *11*(6), 1–21. https://doi.org/10.3390/machines11060586

Susto, G. A., Beghi, A., & De Luca, C. (2012). A predictive maintenance system for epitaxy processes based on filtering and prediction techniques. *IEEE Transactions on Semiconductor Manufacturing*, *25*(4), 638–649. https://doi.org/10.1109/TSM.2012.2209131

Susto, G. A., Schirru, A., Pampuri, S., McLoone, S., & Beghi, A. (2015). Machine learning for predictive maintenance: A multiple classifier approach. *IEEE Transactions on Industrial Informatics*, *11*(3), 812–820. https://doi.org/10.1109/TII.2014.2349359

Tan, W. M., & Teo, T. H. (2021). Remaining Useful Life Prediction Using Temporal Convolution with Attention. *AI (Switzerland)*, *2*(1), 48–70. https://doi.org/10.3390/ai2010005

Wang, J., Wen, G., Yang, S., & Liu, Y. (2019). Remaining Useful Life Estimation in Prognostics Using Deep Bidirectional LSTM Neural Network. *Proceedings - 2018 Prognostics and System Health Management Conference, PHM-Chongqing 2018*, 1037–1042. https://doi.org/10.1109/PHM-Chongqing.2018.00184

Wang, Q., & Wu, G. (2021). Effective Latent Representation for Prediction of Remaining

Useful Life. *Computer Systems Science and Engineering*, *36*(1), 225–237. https://doi.org/10.32604/csse.2021.014100

Wang, T., Guo, D., & Sun, X. M. (2022). Remaining useful life predictions for turbofan engine degradation based on concurrent semi-supervised model. *Neural Computing and Applications*, *34*(7), 5151–5160. https://doi.org/10.1007/s00521-021-06089-1

Wang, Y., & Zhao, Y. (2022). Multi-Scale Remaining Useful Life Prediction Using Long Short-Term Memory. *Sustainability (Switzerland)*, *14*(23). https://doi.org/10.3390/su142315667

Wu, J., Hu, K., Cheng, Y., Zhu, H., Shao, X., & Wang, Y. (2020). Data-driven remaining useful life prediction via multiple sensor signals and deep long short-term memory neural network. *ISA Transactions*, *97*, 241–250. https://doi.org/10.1016/j.isatra.2019.07.004

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. https://doi.org/10.1016/j.neucom.2017.05.063

Xiao, L., Tang, J., Zhang, X., Bechhoefer, E., & Ding, S. (2021). Remaining useful life prediction based on intentional noise injection and feature reconstruction. *Reliability Engineering and System Safety*, Vol. 215. https://doi.org/10.1016/j.ress.2021.107871

Xu, G., Liu, M., Wang, J., Ma, Y., Wang, J., Li, F., & Shen, W. (2019). Data-driven fault diagnostics and prognostics for predictive maintenance: A brief overview. *IEEE International Conference on Automation Science and Engineering*, *2019-Augus*(1), 103–108. https://doi.org/10.1109/COASE.2019.8843068

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. https://doi.org/10.1016/j.ymssp.2019.05.005

Zebari, D. A., Saeed, J. N., Zebari, R. R., & Zeebaree, A. M. A. D. Q. (2020). View of A Comprehensive Review of Dimensionality Reduction Techniques for Feature Selection and Feature Extraction. *Journal of Applied Science and Technology Trends*, *1*, 56–70. https://doi.org/10.38094/jastt1224

Zhang, B., Zheng, K., Huang, Q., Feng, S., Zhou, S., & Zhang, Y. (2020). Aircraft engine prognostics based on informative sensor selection and adaptive degradation modeling with functional principal component analysis. *Sensors (Switzerland)*, Vol. 20. https://doi.org/10.3390/s20030920

Zhang, C., Lim, P., Qin, A. K., & Tan, K. C. (2017). Multiobjective Deep Belief Networks Ensemble for Remaining Useful Life Estimation in Prognostics. *IEEE Transactions on Neural Networks and Learning Systems*, *28*(10), 2306–2318. https://doi.org/10.1109/TNNLS.2016.2582798

Zhang, Y., Xin, Y., Liu, Z. wei, Chi, M., & Ma, G. (2022). Health status assessment and remaining useful life prediction of aero-engine based on BiGRU and MMoE. *Reliability Engineering & System Safety*, *220*, 108263. https://doi.org/10.1016/J.RESS.2021.108263

Zhao, C., Huang, X., Li, Y., & Iqbal, M. Y. (2020). A double-channel hybrid deep neural network based on CNN and BiLSTM for remaining useful life prediction. *Sensors (Switzerland)*, *20*(24), 1–15. https://doi.org/10.3390/s20247109

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. https://doi.org/10.1016/j.ymssp.2018.05.050

Zhao, S., Zhang, Y., Wang, S., Zhou, B., & Cheng, C. (2019). A recurrent neural network approach for remaining useful life prediction utilizing a novel trend features construction method. *Measurement: Journal of the International Measurement Confederation*, *146*, 279–288. https://doi.org/10.1016/j.measurement.2019.06.004

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 2017*, 88–95. https://doi.org/10.1109/ICPHM.2017.7998311