

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**KOŞULLU ÇEKİŞMELİ ÜRETKEN AĞ KULLANARAK DENGESİZ  
VERİLER İLE TORNALAMA İŞLEMLERİNDE  
TIRLAMA TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**Berk Barış Çelik**

**Makina Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Doç. Dr. Hakkı Özgür Ünver**

**AĞUSTOS 2022**



## TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Berk Barış Çelik



## ÖZET

Yüksek Lisans Tezi

### KOŞULLU ÇEKİŞMELİ ÜRETKEN AĞ KULLANARAK DENGESİZ VERİLER İLE TORNALAMA İŞLEMLERİNDE TIRLAMA TESPİTİ

Berk Barış Çelik

TOBB Ekonomi ve Teknoloji Üniversitesi  
Fen Bilimleri Enstitüsü  
Makine Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Hakkı Özgür Ünver

Tarih: Ağustos 2022

Tornalama, tarihteki en eski ve günümüzde de en sık kullanılan talaşlı imalat yöntemlerinden biridir. Tirlama kesici takım ve iş parçası arasındaki kuvvetler sebebiyle oluşan istenmeyen bir titreşim türüdür. Talaşlı imalatta karşılaşılan ve tezgâhlar için en yıkıcı titreşim türü olan tirlama titreşimleri, iş parçasına, kesici takıma ve tezgâhlara zarar verebilmektedir. Tornalamada akıllı veriye dayalı tirlama tespit yöntemlerindeki son gelişmelere rağmen, çoğu çalışmada farklı sınıf koşulları için dengeli eğitim veri setleri olduğu varsayılmaktadır. Bununla birlikte, tirlama görülen sinyallerin toplanması genellikle zor ve pahalıdır, bu durum dengesiz eğitim veri setlerine sebep olmaktadır. Bu tez kapsamında gerçek eğitim verilerine ek olarak dengesiz veri setlerindeki veri dengesizliğini gidermek için derin öğrenmeye dayalı bir tirlama tespit yöntemi önerilmektedir. Veri setlerindeki başta tirlama verisi olmak üzere veri eksikliğini gidermek amacı ile tirlama tespiti çalışmalarında ilk kez bir boyutlu koşullu çekişmeli üretken ağlar kullanılmıştır. Tornalama verileri kolayca sisteme entegre edilebilen bir sensör yardımı ile yapılmıştır. Deneyler kapsamında toplanan verilerdeki gürültü etkilerini gidermek için tirlama tespit çalışmaları kapsamında ilk defa CEEMDAN sinyal ayrıştırma algoritması kullanılmıştır. Farklı senaryolar halinde üretilen sentetik verilerin güvenilirliğini araştırılmıştır. Sonuçlar

ışında üretilen sentetik verilerin ve CEEMDAN algoritmasının tırlama tespitine olan katkıları ortaya konulmuştur.

**Anahtar Kelimeler:** Kendini yenileyen tırlama, tornalama, derin öğrenme, koşullu çekişmeli üretken ağlar, uyarlanabilir gürültü ile tamamlanmış toplu ampirik mod ayrıştırma



## ABSTRACT

Master of Science

### INTELLIGENT CHATTER DETECTION IN TURNING OPERATIONS WITH IMBALANCED DATA USING CONDITIONAL GENERATIVE ADVERSARIAL NETWORKS

Berk Barış Çelik

TOBB University of Economics and Technology  
Institute of Natural and Applied Sciences  
Department of Mechanical Engineering

Supervisor: Assoc. Prof. Hakkı Özgür Ünver

Date: August 2022

Turning is one of the oldest and most frequently used machining methods in history. Chatter is an undesirable type of vibration caused by the forces between the cutting tool and the work piece. Chatter vibrations, which are the most destructive vibration type for machines, can damage the work piece, cutting tool and machines during the machining process. Despite recent advances in smart data-driven chatter detection methods in turning, most studies assume balanced training datasets for different class conditions. However, chatter signals are often difficult and expensive to collect, resulting in unstable training datasets. In this thesis, in addition to real training data, a deep learning-based chatter detection method is proposed to eliminate data imbalance problems. For the first time, one-dimensional conditional generative adversarial networks are used in chatter detection in order to eliminate the lack of data in the datasets, especially the chatter data. Turning data is obtained with the help of a sensor that can be easily integrated into the system. The CEEMDAN decomposition algorithm is used for the first time within the scope of chatter detection studies in order to eliminate the noise effects in the data collected within the scope of the experiments. The reliability of synthetic data produced in different

scenarios is investigated. In the light of the results, the contributions of the synthetic data and the CEEMDAN algorithm to the detection of chatter are presented.

**Keywords:** Regenerative chatter, turning, deep learning, conditional generative adversarial network, Complete ensemble empirical mode decomposition with adaptive noise





## TEŞEKKÜR

Lisans ve yüksek lisans eğitimlerim sürecinde benden yardımlarını esirgemeyen ve kıymetli deneyimlerinden faydalandığım kıymetli hocam Doç. Dr. Hakkı Özgür Ünver'e çok teşekkür ederim. Tez çalışmalarım sürecinde bana yol gösteren kıymetli hocam Doç. Dr. Ahmet Murat Özbayoğlu'na teşekkür ederim.

Eğitim aldığım süreç boyunca engin bilgileri ile bana örnek olan kıymetli Makine Mühendisliği bölümü hocalarıma teşekkür ederim.

Beni bugünlere getiren, sevgisini ve inancını her zaman hissettiğim canım annem Yasemin Çelik'e teşekkür ve minnetlerimi sunarım. Her zaman arkamda bir dağ gibi duran, bugünlere geldiysem en büyük teşekkürü borç bildiğim, ikinci annem Prof. Dr. İlay Erdoğan'a saygı, sevgi ve minnetlerimi sunarım. Hayatını bana ve kardeşime adanmış; üzerimdeki emeği saymakla bitmeyecek, annem, teyzem ve dayım gibi çok kıymetli evlatlar yetiştirmiş sevgili anneannem Satı Erdoğan'a şükran ve minnetlerimi sunarım. Hayattaki en büyük gurur kaynağım, hayatta gördüğüm en güçlü insan, canımın içi kardeşim Özgür Yiğit Çelik'e sevgilerimi sunarım. Makine mühendisi mesleğini seçerken örnek aldığım babam Veli Çelik'e teşekkür ederim.

En güzel anılarımın mimari, birlikte hem gülüp hem ağladığımız, her kararında arkamda duran ve bana inanan, hayatımın geri kalanını birlikte geçirmek için sabırsızlandığım sevgili nişanlım Açelya Şebboy'a teşekkür ve sevgilerimi sunarım.



## İÇİNDEKİLER

	<u>Sayfa</u>
<b>ÖZET</b> .....	v
<b>ABSTRACT</b> .....	vii
<b>TEŞEKKÜR</b> .....	ix
<b>İÇİNDEKİLER</b> .....	xi
<b>ŞEKİL LİSTESİ</b> .....	xiii
<b>ÇİZELGE LİSTESİ</b> .....	xv
<b>KISALTMALAR</b> .....	xvii
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1 Tez Amacı ve Motivasyon .....	2
1.2 Tezin Literatüre Katkıları.....	5
<b>2. ÖN BİLGİ VE LİTERATÜR ARAŞTIRMASI</b> .....	<b>7</b>
2.1 Tornalama ve Torna Dinamikleri.....	7
2.2 Tırlama .....	10
2.3 Tornalamada Yenileci Tırlama .....	12
2.4 Yenileyici Tırlama Altında Tornalama Dinamikleri.....	15
2.5 Tornalamadaki Tırlamanın Analitik Tahmin Yöntemleri .....	21
2.5.1 Stabilite lob diyagramları.....	21
2.6 Tırlama Stabilitesi Tahmini ve Tırlama Tespiti İçin Deneysel Teknikler ..	22
2.6.1 Sinyal toplama ve işleme .....	24
2.6.1.1 Kuvvet ve titreşim ölçümleri.....	25
2.6.2 Talaş Analiz Tekniği.....	26
2.6.3 Yapay zeka teknikleri.....	28
2.7 Sinyal Ayırıştırma Metotları ve CEEMDAN.....	30
2.8 Tırlama Tespitinde Sinyal Ayırıştırma ve AI.....	33
2.9 Veri Dağılımı Eşitsizliği .....	34
2.10 Üretken Modeller .....	35
2.10.1 Çekişmeli üretken ağlar.....	35
2.10.2 Koşullu çekişmeli üretken ağlar.....	37
2.11 Makinelerde Hata Tespiti.....	38
<b>3. DENEYSEL YÖNTEM</b> .....	<b>43</b>
3.1 Takım Tezgahı ve Deneysel Kurulum .....	43
3.2 Sisteme Ait Dinamik Özelliklerin Elde Edilmesi .....	46
3.3 Sinyal Önışleme .....	50
3.4 CGAN Tasarımı .....	51
3.5 Eğitim ve Performans Analizi .....	55
3.5.1 Veri setinin hazırlanışı .....	54
3.5.2 CGAN eğitimi ve sentetik veri üretimi .....	56
3.5.3 PCA analizi .....	59
3.5.4 Veri üretiminin değerlendirilmesi .....	61
<b>4. SONUÇLAR</b> .....	<b>67</b>
<b>KAYNAKLAR</b> .....	<b>69</b>
<b>ÖZGEÇMİŞ</b> .....	<b>75</b>



## ŞEKİL LİSTESİ

### Sayfa

Şekil 1.1: Analitik tırlama tahmin tekniklerini içeren yayın sayısı ve 1965 ile 2012 yılları arasında yapılmış yayınların özetini gösteren tablo .....	2
Şekil 1.2: Deneysel tırlama tespit tekniklerini içeren yayın sayısı ve 1946 ile 2012 yılları arasında yapılmış yayınların özetini gösteren tablo. ....	3
Şekil 1.3: Makine öğrenimini kullanımı ile makinelerde akıllı arıza teşhisinin geliştirilmesi ve kilometre taşları.....	4
Şekil 2.1: Torna tezgahının temel elemanları. ....	7
Şekil 2.2: Kesme kuvveti ve bu kuvvete ait normal ve teğetsel komponentler dik kesme operasyonu için gösterilmiştir.....	8
Şekil 2.3: Kesim kuvveti dinamometresi ile kuvvet ölçümü. ....	9
Şekil 2.4: Tırlama sonucunda oluşmuş, istenmeyen bir kesim yüzeyi. ....	11
Şekil 2.5: Tornalamadaki tırlamanın abartılı bir gösterimi.....	12
Şekil 2.6: Bir önceki devirdeki yüzeyden tornalama tasviri. ....	13
Şekil 2.7: Anlık talaş kalınlığı hesabını gösteren şema.....	14
Şekil 2.8: Devirler arasındaki yüzey dalgalanması aynı fazdadır. İhmal edilebilir talaş kalınlığı değişimi elde edilir.....	14
Şekil 2.9: Devirler arasında daha az elverişli faz ilişkisi, önemli talaş kalınlığı varyasyonu vardır.....	14
Şekil 2.10: Tezgâh ile kesim işlemi etkileşimi.....	16
Şekil 2.11: Yenilenme mekanizması şematik gösterimi .....	16
Şekil 2.12: Tek serbestlik dereceli ortogonal tornalama modeli.....	18
Şekil 2.13: Çeşitli hızlar ve kesme genişlikleri için stabilite lobları/bölgelerini gösteren bir SLD. ....	20
Şekil 2.14: 1946-2012 yılları arasında sinyal toplama tekniklerini içeren yayın sayısı grafiği ve seçilen yayınların özetini gösteren tablo.....	24
Şekil 2.15: Torna işlemi sırasında ortaya çıkmış bir talaş örneğinin mikroskop altındaki görüntüsü.....	26
Şekil 2.16: Tırlama oluşumu tahmin prosedürü algoritması.....	29
Şekil 2.17: Farklı IMF'lerin korelasyon katsayıları (EMD).....	32
Şekil 2.18: Farklı IMF'lerin korelasyon katsayıları (EEMD).. ....	33
Şekil 2.19: EMD, EEMD ve CEEMDAN karşılaştırması.. ....	33
Şekil 2.20: Üretici ağlardaki için veri sentezleme sistemi .....	35
Şekil 2.21: GAN yapısı. ....	36
Şekil 2.22: CGAN yapısı.....	38
Şekil 2.23: İki arıza durumunun orjinal ve üretilen TF görüntüleri: (a) IRF durumunun orjinal görüntüsü; (b) IRF durumunun sentezlenmiş görüntüsü; (c) ORF durumunun orijinal görüntüsü; (b) ORF durumunun sentezlenmiş görüntüsü.....	39
Şekil 2.24: Tırlamalı ve kararlı örneklere ait hata haritaları .....	39
Şekil 2.25: Orijinal titreşim sinyallerinin zaman alanı ve frekans alanı örnekleri.....	40
Şekil 2.26: Önerilen metoda ait akış şeması. ....	41

Şekil 3.1: Tez kapsamında izlenen yöntemi özetleyen akış şeması. ....	44
Şekil 3.2: MAZAK Integrex i-200ST yatay işleme merkezi. ....	44
Şekil 3.3: Deneysel kurulum ve test ekipmanları.....	46
Şekil 3.4: Bitişik takım konumuna ait FRF.....	46
Şekil 3.5: Ayrık takım konumuna ait FRF .....	47
Şekil 3.6: İki farklı takım konumuna ait SLD'ler a) Ayrık takım konumu b) Bitişik takım konumu.....	48
Şekil 3.7: Kayar pencere uygulaması.....	51
Şekil 3.8: Tez kapsamında kullanılmış CGAN mimarisi. ....	52
Şekil 3.9: CGAN (ham sinyal girdisi) eğitim performansı a) jeneratör yitimi b) diskriminatör yitimi. ....	56
Şekil 3.10: CGAN (CEEMDAN girdisi) eğitim performansı a) jeneratör yitimi b) diskriminatör yitimi. ....	57
Şekil 3.11: Puan açısından CGAN (ham girdi ile) performansı.....	57
Şekil 3.12: Puan açısından CGAN (CEEMDAN girdisi ile) performansı. ....	58
Şekil 3.13: Dört veri setinden gerçek sinyal örnekleri ile birlikte iki CGAN'dan aynı veri setleri girdi verilerek sentezlenmiş sentetik sinyal örnekleri. ....	59
Şekil 3.14: Gerçek ve sentetik (ham girdili CGAN'dan elde edilmiş) örneklerin özellik dağılım grafikleri a) tırlama örnekleri b) kararlı örnekler. ....	60
Şekil 3.15: Gerçek ve sentetik (CEEMDAN girdili CGAN'dan elde edilmiş) örneklerin özellik dağılım grafikleri a) tırlama örnekleri b) kararlı örnekler.....	60
Şekil 3.16: Farklı veri setlerine ait Öklid mesafesi değerlerine ait kutu grafikleri. ...	62
Şekil 3.17: Farklı veri setlerine ait varyans değerlerine ait kutu grafikleri.....	62
Şekil 3.18: Senaryo setleri için ortalama sınıflandırma doğrulukları.....	65

## ÇİZELGE LİSTESİ

### Sayfa

Çizelge 2.1: Seçilen iş parçası malzemeleri için temsili $K_s$ değerleri.....	9
Çizelge 3.1: Kesici takım, kesim ve iş parçası parametreleri. ....	45
Çizelge 3.2: MAZAK Integrex i-200ST yatay işleme merkezi özellikleri. ....	45
Çizelge 3.3: Yapılan tüm kesimlere ait parametreler. ....	47
Çizelge 3.4: Jeneratör ağına ait tüm katmanlar ve bu katmanlara ait özellikler. ....	55
Çizelge 3.5: Diskriminatör ağına ait katman yapısı ve bu katmanlara ait parametreler. .....	54
Çizelge 3.6: CGAN eğitiminde kullanılmış hiperparametreler.....	55
Çizelge 3.7: Birinci senaryo seti (ham veri seti için). ....	63
Çizelge 3.8: İkinci senaryo seti (CEEMDAN veri seti için). ....	63
Çizelge 3.9: Farklı senaryo setlerine ait sınıflandırma başarıları (%). ....	64
Çizelge 3.10: Tüm testlere ait güvenilirlik analizi için hesaplanan varyans değerleri .....	65





## KISALTMALAR

<b>AI</b>	: Artificial Intelligence (Yapay Zeka)
<b>AE</b>	: Auto Encoder (Otomatik Kodlayıcı)
<b>ANN</b>	: Artificial Neural Network (Yapay Sinir Ağı)
<b>BN</b>	: Batch Normalization (Grup Normalizasyonu)
<b>CEEMD</b>	: Complete Ensemble Empirical Mode Decomposition (Tamamlanmış Toplu Ampirik Mod Ayırıştırma)
<b>CEEMDAN</b>	: Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (Uyarlanabilir Gürültü ile Tamamlanmış Toplu Ampirik Mod Ayırıştırma)
<b>CNC</b>	: Computer Numerical Control (Bilgisayarlı Sayısal Kontrol)
<b>CNN</b>	: Convolutional Neural Network (Konvolüsyonel Sinir Ağları)
<b>CGAN</b>	: Conditional Generative Adversarial Network (Koşullu Üretken Çekişmeli Ağ)
<b>CWT</b>	: Continuous Wavelet Transform (Sürekli Dalgacık Dönüşümü)
<b>DAQ</b>	: Data Acquisition (Veri Edinimi)
<b>DL</b>	: Deep Learning (Derin Öğrenme)
<b>DNN</b>	: Deep Neural Network (Derin Sinir Ağı)
<b>EEMD</b>	: Ensemble Empirical Mode Decomposition (Toplu Ampirik Mod Ayırıştırma)
<b>EMD</b>	: Empirical Mode Decomposition (Ampirik Mod Ayırıştırma)
<b>FFT</b>	: Fast Fourier Transform (Hızlı Fourier Dönüşümü)
<b>FRF</b>	: Frequency Response Function (Frekans Tepki Fonksiyonu)
<b>GAN</b>	: Generative Adversarial Network (Üretken Çekişmeli Ağ)
<b>HMM</b>	: Hidden Markov Model (Gizli Markov Modeli)
<b>IMF</b>	: Intrinsic Mode Function (İçkin Kip Fonksiyonu)
<b>IRF</b>	: Inner Ring Fault (İç Yüzük Hatası)
<b>LReLU</b>	: Leaky Rectifier Linear Unit (Sızan Doğrultulmuş Lineer Birim)
<b>ML</b>	: Machine Learning (Makine Öğrenmesi)
<b>NF</b>	: Normal Flow (Normal Akış)
<b>ORF</b>	: Outer Ring Fault (Dış Yüzük Hatası)
<b>ReLU</b>	: Rectifier Linear Unit (Doğrultulmuş Lineer Birim)
<b>RMS</b>	: Root Mean Square (Karekök Ortalama)
<b>RPM</b>	: Rotation per Minute (Dakika Başına Dönüş)
<b>SEM</b>	: Scanning Electron Microscope (Taramalı Elektron Mikroskobu)
<b>SLD</b>	: Stability Lobe Diagram (Stabilite Lob Diagramı)
<b>SVM</b>	: Support Vector Machine (Destek Vektör Makinesi)
<b>TF</b>	: Time-frequency (Zaman-frekans)
<b>VAE</b>	: Variational Auto Encoder (Varyasyonel Otomatik Kodlayıcı)
<b>VMD</b>	: Variational Mode Decomposition (Varyasyonel Mod Ayırıştırması)
<b>WPT</b>	: Wavelet Packet Transform (Dalgacık Paket Taşınımı)



## 1. GİRİŞ

Talaşlı imalat, tüm endüstrilerde en çok kullanılan imalat süreçlerinden biridir. En yaygın olan formları ve tornalama ve frezelemedir. Tornalamada dönen bir iş parçasından talaş kaldırmak için sabit bir kesim aleti kullanılır. Frezelemede ise monte edilmiş iş parçasından talaş kaldırmak için dönen bir kesim parçası bulunur. Daha başarılı sonuçlar ve tekrarlanabilirlik elde etmek için CNC cihazları geliştirilmiştir.

Bu buluş çıkış zamanına göre büyük bir adımdı, ancak yıllar içinde bu sistemleri daha akıllı hale getirmek için oldukça az iyileştirme yapılmıştır. CNC ile işlemeyi verimli ve güvenli hale getirebilmek için süreç izleme ve süreç iyileştirme yapılmalıdır. Otomatik süreç izleme ve iyileştirme yapabilmek için sensör sinyallerini anlamayı ve yorumlamayı sağlayacak bazı metotlar ve algoritmalar gereklidir. Bu metotlar ve algoritmalar ile otomotiv, savunma, medikal gibi endüstrilerde kullanılan talaşlı imalat yöntemlerinin işleme kalitesinin artırılması, takım ömürlerinin uzatılması amaçlanmaktadır. Tırlama titreşimleri hemen hemen tüm kesme işlemlerinde mevcuttur ve bu titreşimler istenilen üretkenliğe ulaşmanın önündeki en büyük engeldir. Rejeneratif tırlama, takım ile iş parçası arasında aşırı titreşim oluşturduğundan, zayıf yüzey kalitesi, yüksek aralıklı gürültü ve takım aşınmasının hızlanmasına neden olduğu için herhangi bir işlem için en zararlı olanıdır ve bu da takım tezgâhı ömrünü, işlemenin güvenilirliğini ve operasyon güvenliğini azaltır [1].


Bu tez kapsamında MAZAK Integrex i-200ST 5 eksenli yatay işleme merkezi ile yapılan deneyler ile toplanan kesim verileri ile derin öğrenme metotları ile yapay kesim verileri üretilmesi ve bu veriler ile tırlama tespit çalışmaları yapılmıştır. Hassas deney ortamlarına gerek duymadan veri toplanmasına olanak sunun üç eksenli ivmeölçer ile veriler toplanmıştır. Stabilitate lob diyagramlarına göre elde edilen tırlama bilgilerinin, sinyal ayrıştırma ve makine öğrenmesi metotları bulguları ile örtüştüğü gösterilmiştir. Bunlara ek olarak, tez kapsamında üretilen sentetik veriler günümüzde kullanılan en güçlü üretken derin öğrenme metotlarından biri olan

CGAN ile sentezlenmiştir. Ayrıca GAN’larda sıklıkla karşılaşılan mod çarpışması ve yakınsamama problemlerine uygulaması zor olmayan ve oldukça etkili çözüm önerileri getirilmiştir.

## 1.1 Tez Amacı ve Motivasyon

Bu tezin başlıca amacı, tırlama tespitindeki veri dengesizliği problemine derin öğrenme metotları yardımıyla çözüm bulmaktır. Bu çözümü ararken kronikleşmiş bazı derin öğrenme algoritma problemlerine çözüm aramak ve bu sırada en güncel sinyal işleme metotlarından yararlanmaktır.

Tornalama operasyonunda tırlama tespiti konularında uzun yıllardır çalışmalar devam etmektedir. Geçtiğimiz yıllarda yapılan bir çalışmada yapılan yayın sayısı ve konularına ait bulgular ortaya konulmuştur. 1965-2012 yılları arasında tornalamada analitik tırlama tahmini konusu ile ilgili yapılan yayın ve yayın konuları ile ilgili bilgiler Şekil 1.1 ‘de, 1946-2012 yılları arasında tornalamada deneysel tırlama tespiti konusu ile ilgili yapılan yayın ve yayın konuları ile ilgili bilgiler Şekil 1.2’de gösterilmiştir.



**Şekil 1.1:** Analitik tırlama tahmin tekniklerini içeren yayın sayısı ve 1965 ile 2012 yılları arasında yapılmış yayınların özetini gösteren tablo [1].

Makinelerde arıza teşhisi, makine izleme verileri ile sağlık durumları arasındaki ilişkinin izlenmesinde önemli bir rol oynar. Aynı zamanda, makine sağlığı yönetiminde yaygın olarak ilgilenilen bir konu olmuştur [2,3]. Geleneksel olarak, bu ilişki deneyim ile ve mühendislerin uzmanlık bilgisi ile kurulmuştur. Tasarım eniyilemesi için kullanılmıştır. Elde edilen sonuçlar, yüzey şekillendirilmesiyle plakanın özgül kinetik enerji soğurma kapasitesinin %56 oranında arttırılabildiğini

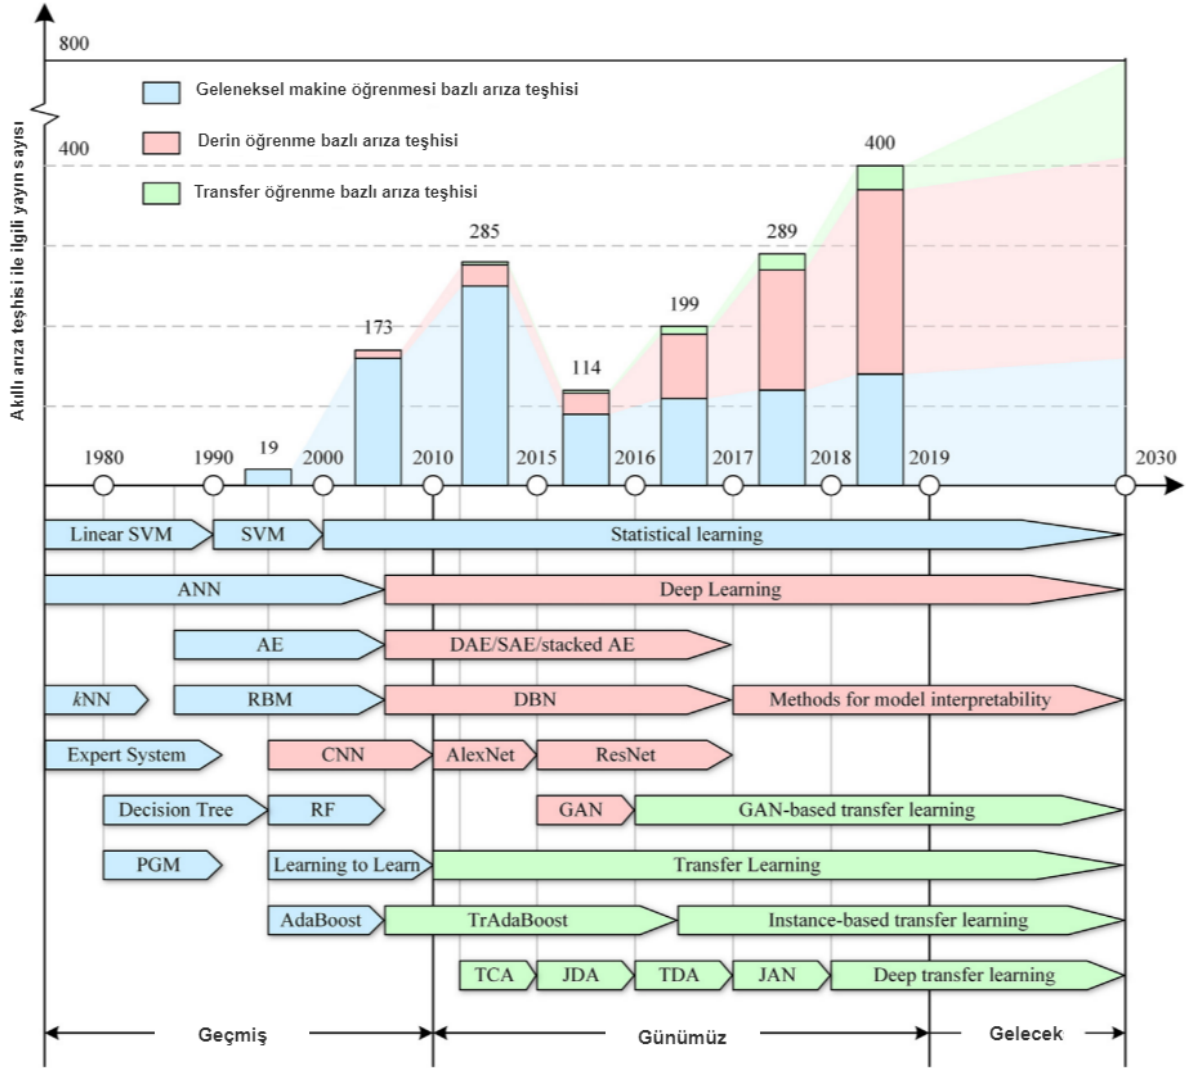
göstermektedir. Örneğin, deneyimli bir mühendis anormal bir sese bağlı olarak motor arızalarını teşhis edebilir veya titreşim sinyallerini analiz etmek için gelişmiş sinyal işleme yöntemlerini kullanarak makine arızalarını tespit edebilir. Ancak mühendislik senaryolarında, makine kullanıcıları bakım döngüsünü kısaltmak ve teşhis doğruluğunu iyileştirmek için otomatik bir yönteme ihtiyaç duymaktadırlar. Özellikle yapay zekâ ile arıza teşhis prosedürünün, makinelerin sağlık durumlarını ve arızalarını otomatik olarak algılayacak ve tanıyacak kadar akıllı olması beklenmektedir.



**Şekil 1.2:** Deneyisel tırlama tespit tekniklerini içeren yayın sayısı ve 1946 ile 2012 yılları arasında yapılmış yayınların özetini gösteren tablo [1].

Akıllı arıza teşhisi, ANN gibi makine öğrenimi teorilerinin uygulamalarını ifade etmektedir. ANN, SVM ve DNN makine arıza teşhisi için umut verici yöntemlere bazı örneklerdir [4,5]. Bu tür yöntemler, mühendislerin deneyim ve bilgisinden yararlanmak yerine teşhis bilgilerini uyarlamalı olarak öğrenmek için makine öğrenimi teorilerini kullanır. Akıllı arıza teşhisi özellikle, toplanan veriler ve makinelerin arıza durumları arasında otomatik olarak köprü kurabilen modeller oluşturmayı amaçlamaktadır.

Son yıllarda makine öğreniminin gelişimi ile akıllı arıza teşhisi konusu akademik araştırmacıların ve endüstri mühendislerinin büyük ilgisini çekmiştir [5,6,7]. Araştırmaya dayalı olarak arıza teşhisinde makine öğrenimi metotları kullanan yayınların sayısı Web of Science verilerine göre belirlenmiştir. Bu veriler Şekil 1.3'te gösterilmiştir.



**Şekil 1.3:** Makine öğrenimini kullanımı ile makinelerde akıllı arıza teşhisinin geliştirilmesi ve kilometre taşları [2].

Yapay zekâ uygulamalarının gelişmesi ile hata tespiti ve özellikle tırlama tespiti alanlarında birçok çalışma yapılmıştır. Hata teşhisi, tırlama tespiti ve sentetik veri üretimi alanlarındaki çalışmalar incelenmiştir. Bu çalışmalar ilerleyen bölümlerde sunulmuştur. Özellikle tırlama tespitinde sentetik veri üretimi konusunda büyük bir boşluk bulunmaktadır. Rulmanlarda, rotorlarda ve dişli kutuları gibi araçlardaki hata tespit yaklaşımlarında, derin öğrenme ile sentetik veri üretimi oldukça yaygın iken tırlamada aynı durum söz konusu değildir. Bu yüksek lisans tezinin motivasyonu aşağıdaki gibi sıralanabilir;

- Tırlama tespitinde, veri setlerindeki veri dengesizliği en önemli sorunlardan biridir. Bu sorun derin öğrenme metotları ile çözülebilir fakat bu alanda yeteri kadar çalışma bulunmamaktadır.
- Sinyal ayrıştırma yöntemlerinde yıllar içinde çok önemli gelişmeler yaşanmıştır. Fakat tırlama tespiti konusunda halen eski sinyal ayrıştırma yöntemlerinin kullanımı yaygındır.
- Sentetik veri üretiminde genellikle görüntü veya sinyalin orijinal halinden uzaklaşmış, bazı işlemlerden geçirilmiş halleri girdi olarak kullanılmaktadır. Sinyallerin ham hallerini girdi olarak kullanarak sinyal karakteristiği korunması zahmetli olduğu için diğer yöntemlere göre geri planda kalmıştır.

## 1.2 Tezin Literatüre Katkıları

Yukarda sözü geçen problemlere çözüm getirme amacıyla yapılmış çalışmalar sonucunda literatüre, torna tezgâhlarındaki tırlama tespitindeki veri eşitsizliğine yönelik sentetik veri üretimi yaklaşımı, bu tezin yazıldığı aşamada bir ilk olarak kazandırılmıştır. Bu tezin halihazırda var olan çalışmalardan farklı olarak sunduğu katkılar aşağıda verilmiştir.

- Çalışma kapsamında kullanılmış tüm veriler deneyler ile toplanmıştır. Simülasyon verisi kullanılmamıştır. Bu sayede gerçek hayattaki kullanımın önünü açmaktadır.
- Tırlama tespitinde ilk kez CEEMDAN sinyal ayrıştırma algoritması kullanılmıştır. Alınan oldukça iyi sınıflandırma sonuçları sayesinde CEEMDAN algoritmasının tırlama sinyallerinin ayrıştırılmasında kullanılabileceği kanıtlanmıştır.
- Tırlama tespitindeki veri dengesizliğine çözüm getirmek için literatürde ilk kez bir boyutlu sinyal girdisi olan koşullu çekişmeli üretken ağlar kullanılmıştır.






## 2. ÖN BİLGİ VE LİTERATÜR ARAŞTIRMASI

### 2.1 Tornalama ve Torna Dinamikleri

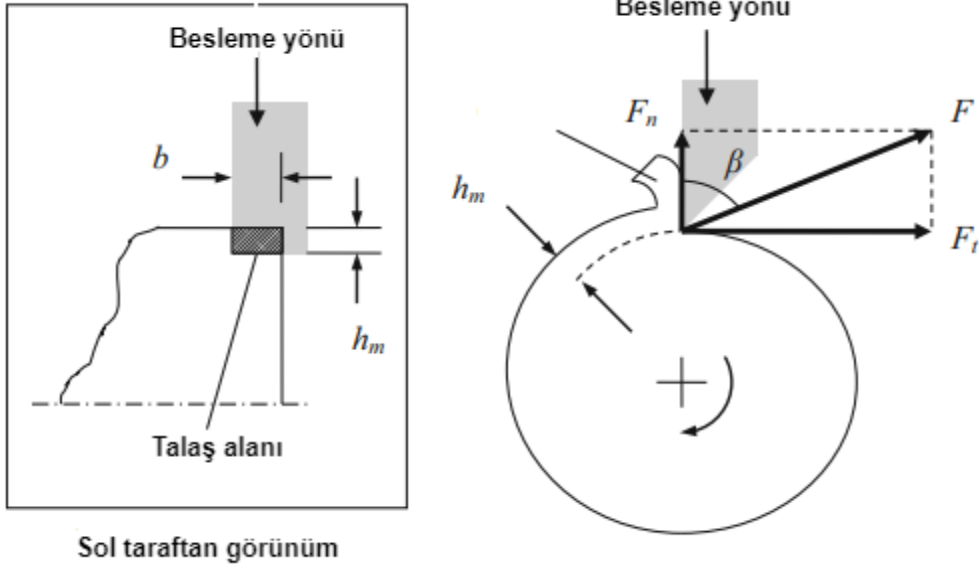
Tornalama işlemleri genellikle iş parçasının döndürüldüğü bir torna tezgâhında gerçekleştirilir. Aksi simetrik parçaya istenen şekli vermek için iki eksenli bir kızağa monte edilmiş bir kesici uç iş parçasından talaş kaldırır. Torna tezgâhının şematik gösterimi Şekil 2.1’te verilmiştir.



**Şekil 2.1:** Torna tezgâhının temel elemanları [8].

İş parçasının son şekli hem iç hem de dış özellikler içerebilir. Torna, bir teknisyenin sürgüyü kontrol ettiği manuel şekilde veya talaş kaldırma sırasındaki pozisyonların bir bilgisayar ile belirlendiği CNC şeklinde olabilir. Parça programı istenen iş parçasının boyutlarına dayalıdır ve tipik olarak bilgisayar destekli tasarım/bilgisayar destekli üretim yazılımı (CAD/CAM) kullanılarak geliştirilmiştir.

Takım ve iş parçası rijit olarak kabul edilecek olursa Şekil 2.2 dik kesim operasyonunu göstermektedir. Burada  $F$  kesme kuvveti,  $F$ 'in normal ve teğetsel komponentleri sırası ile  $F_n$  ve  $F_t$ 'dir.



**Şekil 2.2:** Kesme kuvveti ve bu kuvvete ait normal ve teğetsel komponentler dik kesme operasyonu için gösterilmiştir [8].

Genel olarak, kesme kuvveti vektörü, hat boyunca üçüncü bileşeni içerir ancak ortogonal (düzlemsel) işlem, süreç dinamiklerini tanımlamamız için yeterlidir. Şekil ayrıca (1) ortalama talaş kalınlığını  $h_m$  ya da resimde görülen karşıya alma işlemi için devir başına komut verilen ilerleme ve (2)  $F$  ve  $F_n$  arasındaki kuvvet açısı,  $\beta$ 'yi tanımlamaktadır. Bu işlemin yandan görünüşü talaş genişliğini gösterir,  $b$ . Talaş kalınlığı ve talaş genişliği birlikte kaldırılacak malzeme miktarı alanı tanımlar,  $A = bh_m$  Bu sürece bağlı katsayı, [9]'da özgül (veya birim çip alanı başına) kuvvet,  $K_s$  olarak adlandırılır ve şunlara bağlıdır: iş parçası malzemesi, takım geometrisi, daha az ölçüde kesme hızı (dönen iş parçasının çevresel hızı) ve talaş kalınlığı.

$$F = K_s A = K_s b h_m \quad (2.1)$$


Normal ve teğetsel bileşenler,  $F_n$  ve  $F_t$ ,  $F$  kullanılarak ifade edilebilir ve kuvvet açısı:

$$F_n = \cos(\beta) F = \cos(\beta) K_s b h_m = k_n b h_m \quad (2.2)$$

$$F_t = \sin(\beta) F = \sin(\beta) K_s b h_m = k_t b h_m \quad (2.3)$$

Kesme kuvveti katsayılarının  $k_n$  ve  $k_t$  tanımlandığı yer  $K_s$  ve  $\beta$  ile burada tanımlanmıştır. Bu katsayıları elastik temelli hesaplamaya yönelik çabalar devam etse de ve plastik malzeme özellikleri, bunları karakterize etmek için kullanılan ortak bir yaklaşım sürece bağlı değerler, bilinen kesme koşullarını belirlemek ve ölçmektir. Takım doğrudan bir kesme kuvveti dinamometresine monte edilmişse Şekil 2.3'de

gösterildiği gibi ve  $b$  ve  $h_m$  değerleri biliniyorsa, ölçülen kuvvet Denklemler 2.2 ve 2.3 yeniden yazılarak katsayıları belirlemek için bileşen değerleri kullanılabilir,  $k_n = F_n / bh_m$  ve  $k_t = F_t / bh_m$ 'dir.  $k_n$ ,  $k_t$  ve  $K_s$  için birimler  $N/mm^2$ 'dir.



**Şekil 2.3:** Kesme kuvveti ve bu kuvvete ait normal ve teğetsel komponentler dik kesme operasyonu için gösterilmiştir [8].

Belirli bir uygulamaya özel olan bazı seçilmiş örnek  $K_s$  değerleri Çizelge 2.1'de verilmiştir.

**Çizelge 2.1:** Seçilen iş parçası malzemeleri için temsili  $K_s$  değerleri [9].

Malzeme	$K_s (N/mm^2)$	Malzeme	$K_s (N/mm^2)$
Gri döküm demiri	1500	Ni bazlı Inconel X	3400
1020 karbon çeliği	2100	Ni bazlı Udimet 500	3500
1035 karbon çeliği	2300	Co bazlı L605	3500
1045 karbon çeliği	2600	Ti6Al4V	2000
302 paslanmaz çelik	2700	Al 7075-T5	850
4140/5140 alaşım çeliği	2800	Al 6061-T6	750

## 2.2 Tırlama

Tırlama ilk olarak Taylor tarafından 1800'lerde, talaşlı üretiminin bir sınırlaması olarak tanımlandı. 3/4 güç yasası kesme kuvvet modeli türetilmiş ve tırlamanın "teknisyenin yaşadığı tüm sorunlardan en belirsiz ve hassas olanıdır" [1,10]. Arnold bir takımın kesim sırasında maruz kaldığı sayısız etkiyi inceledi ve tırlamayı oluşturan mekanizmaların ve belirtilmiş kesme kuvvetlerinin hızın bir fonksiyonu olduğunu gösterdi [11]. Tırlama titreşiminin en önemli karakteristiği dış periyodik kuvvetler tarafından indüklenmediği aksine, onu var eden ve sürdüren kuvvetler, titreşimli işlemin (dinamik kesme işlemi) kendisinden kaynaklanmasıdır.

Tırlama ilk defa Tobias ve Fishwick ve Tlusty ve Polacek tarafından kesim işlemlerindeki istikrarsızlıktan dolayı anlaşılmıştır [12,13]. Dinamik kesim kuvvetlerinin etkilediği titreşimler tarafından etkilenen talaş kalınlığının, titreşim genliğini arttırdığı gözlemlenmiştir ve bu fenomene yenilenebilir tırlama denilmiştir. Ayrıca kesim kalınlığının kesim işlemi kararlılığındaki anahtar parametre olduğu da gözlemlenmiştir. Tlusty ve Polacek bir kararlılık koşulu sunmuştur [13]. Bu çözüm kesme kuvvetleri ve yapısal dinamikleri çözerek yaklaşık yalnızca bir yöne, yani talaş kalınlığı yönüne ve böylece sadece tek boyutlu bir süreç için geçerlidir. Tobias ve Meritt dinamik tepkinin modellenmesi, yapısal yönlerini ve tırlamanın kararlılık limitlerini hakkında çalışmalar yürütmüşlerdir [14,15]. Bu çalışmalar yalnızca kesme kuvveti yönünün sistem dinamiklerinin ve talaş kalınlığının zamanla değişmediği dik kesim için geçerlidir.


Tornalama prosesinde dinamik sertlik/rijitlik eksikliğinden kaynaklanan üç farklı titreşim mevcuttur [16]. Bunlar serbest, zorlanmış ve kendinden tahrikli titreşimlerdir. Serbest titreşimler, dişli, rulman ve mil yatağı gibi makine elemanlarının montajlarındaki dengesizlikten oluşan şok ve zorlamalı titreşimlerden meydana gelmektedir. Serbest ve zorlanmış titreşimler kolayca tanımlanabilir ve ortadan kaldırılabilir. Fakat kendinden tahrikli tırlama titreşimleri, karmaşık doğaları gereği halen tam olarak anlaşılabilmiş değildir. Bu titreşim türleri tüm talaşlı imalat prosesleri için en tehlikeli titreşim türleridir.

Kendinden tahrikli titreşim türleri genel olarak birincil tırlama ve ikincil tırlama olarak tanımlanmaktadır [17]. Birincil tırlama takım-iş parçası arasındaki sürtünme, termo-mekanik etkiler veya mod birleştirmeden kaynaklanmaktadır. İkincil tırlama

ise, iş parçası üzerindeki dalgalı yüzeyin yenilenmesinden kaynaklanmaktadır. Rejeneratif titreşim diğer tüm titreşimler arasında en yıkıcı olanıdır. Yenilenebilir tırlamanın önden tespiti ve engellenmesi için birçok çalışma yapılmıştır. Birçok araştırmacı aktif veya pasif kontrol stratejileri ile tırlamayı kontrol etmeye çalıştılar. Tırlama analiz süreci, tırlama kararlılık tahmini ve tırlama tespiti oldukça karmaşık konulardır ve tornalama, frezeleme ve delme gibi talaşlı imalat işlemleri için ayrı ayrı incelenmelidir.

Tırlamanın sebep olduğu birçok problem ve zarar bulunmaktadır. Bu zararlar üretim zamanlarında uzamalara, takım ve makine ömürlerindeki kısalmalara sebebiyet verebilir. Şekil 2.4'te bu çalışma kapsamında yapılan deneyler sırasında çekilmiş, tırlama sonucunda oluşmuş istenmeyen bir kesim yüzeyi gösterilmiştir. Tırlamanın sebep olduğu başlıca aşağıdaki gibidir;


- Üretim veriminde önemli kısıtlamalara sebep olur.
- Kötü yüzey kalitelerine yol açar [18].
- Ekstra malzeme atıkları oluşmasına neden olur.
- Kesici takım ve tezgâhta tahribata sebep olur [19].
- İstenmeyen gürültülere yol açar.



**Şekil 2.4:** Tırlama sonucunda oluşmuş, istenmeyen bir kesim yüzeyi.

### 2.3 Tornalamada Yenileyici Tırlama


Rijit takım varsayımını kaldırırsak, kesme kuvvetinin kesici takımda sapmalara neden olacağı açıktır. Aletin sertliği ve kütlesi olduğu için titreşebilir. Takım malzemeyi kaldırırken titreşiyorsa, bu titreşimler iş parçası yüzeyinde dalgalı bir profil olarak kalır. Şekil 2.5 iş parçası yüzeyi ile ilk darbenin takımın titreşmeye başlamasına ve normal yöndeki salınımların iş parçasına kopyalanmasına neden olduğu abartılı bir görünümü göstermektedir.



**Şekil 2.5:** Tornalamadaki tırlamanın abartılı bir gösterimi [8].

İş parçası ikinci devrine başladığında, titreşimli takım ilk devir sırasında üretilen dalgalı yüzeyle karşılaşır. Bu nedenle, herhangi bir andaki talaş kalınlığı hem o andaki takım sapmasına hem de önceki devirden itibaren iş parçası yüzeyine bağlıdır. Takımın titreşimi bu nedenle, Denklem 3.1'e göre, kuvvet talaş kalınlığıyla orantılı olduğundan değişken bir kesme kuvveti verecek olan değişken bir talaş kalınlığına yol açar. Kesme kuvveti, mevcut takım sapmasını yönetir ve ardından sistem geri bildirim sergiler. Başka bir deyişle, mevcut davranış önceki davranışa bağlıdır yani sistemin bir hafızası vardır.

Modelleme açısından bakıldığında, "dalgalılığın yenilenmesi", talaş kalınlığı denkleminde zaman gecikmeli bir terim olarak görünür. Şekil 2.6, soldaki yüzeyin önceki devirde üretildiği ve takımın sağındaki yüzeyin (devir başına ortalama ilerleme ile ofset) salınımlı takım tarafından kesildiği tornalama işleminin açılmış bir görünümünü göstermektedir. Sadece talaş kalınlığı üzerinde en doğrudan etkiye sahip olan normal yöndeki,  $y$  (kesimin dışındaki pozitif yön) titreşimler dikkate alınacaktır.




**Şekil 2.6:** Bir önceki devirdeki yüzeyden tornalama tasviri [8].

Zamana bağlı, anlık talaş kalınlığı,  $h(t)$ , Denklem 2.4 kullanılarak belirlenir.


$$h(t) = h_m + y(t - \tau) - y(t) \quad (2.4)$$

Bir önceki devirde,  $y(t - \tau)$ ,  $\tau$  'nun bir dönüş zamanı olduğu daha büyük pozitif titreşimin artan bir talaş kalınlığı verdiği (yani, mevcut talaşın daha kalın olması için daha az malzeme çıkarıldığı) görülmektedir. Öte yandan, daha büyük pozitif akım titreşimi  $y(t)$  daha ince bir talaş ortaya çıkarır. Şekil 2.7'de gösterilmiştir. Devir başına ortalama ilerlemeye, mevcut sapmaya ve iş parçasının önceki devri sırasındaki (aletin solundaki) titreşime bağlıdır.


Bir geçişten diğerine yüzey dalgalanması arasındaki bağıl fazlama, kuvvet değişiminin seviyesini ve işlemin kararlı mı yoksa kararsız (tırlama) mı olduğunu belirler. Şekil 2.8 ve Şekil 2.9 iki olasılığı göstermektedir.



Şekil 2.7: Anlık talaş kalınlığı hesabını gösteren şema [8].



Şekil 2.8: Devirler arasındaki yüzey dalgalanması aynı fazdadır. İhmal edilebilir talaş kalınlığı değişimi elde edilir [8].



Şekil 2.9: Devirler arasında daha az elverişli faz ilişkisi, önemli talaş kalınlığı varyasyonu vardır [8].



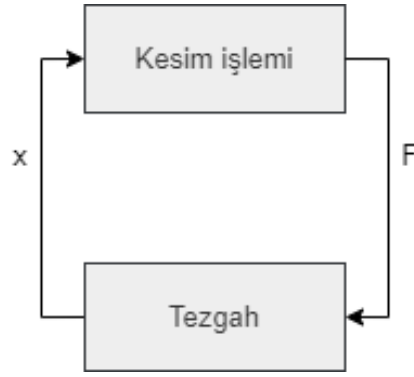
Şekil 2.8’de iki devir arasındaki dalgalı yüzeyler aynı fazdadır. Bu nedenle, malzeme kaldırma sırasında titreşim mevcut olsa bile, talaş kalınlığı değişimi (iki eğri arasındaki dikey mesafe) ihmal edilebilir ve kayda değer bir kuvvet değişimi yoktur. Bu, daha büyük talaş genişliklerinde dengeli kesme sağlar. Takımın doğal frekansında titreşme eğiliminde olduğu göz önüne alındığında, iş parçası dönüş frekansını (iş mili hızı) takımın doğal frekansıyla eşleştirmenin bu tercih edilen "fazda" duruma yol açacağı sezgiseldir. Ancak bu, sistemi doğal frekansında sürmekten kaçındığımız geleneksel rezonans anlayışımıza dayalı olarak sezgiseldir. Şekil 2.9, talaş kalınlığında önemli bir değişimin olduğu daha az elverişli bir faz ilişkisini göstermektedir. Bu, kuvvet değişimleri ve müteakip takım sapmaları nedeniyle önceki duruma göre daha küçük talaş genişliklerinde kararsız kesmeye yol açar.

#### **2.4 Yenileyici Tırlama Altında Tornalama Dinamikleri**

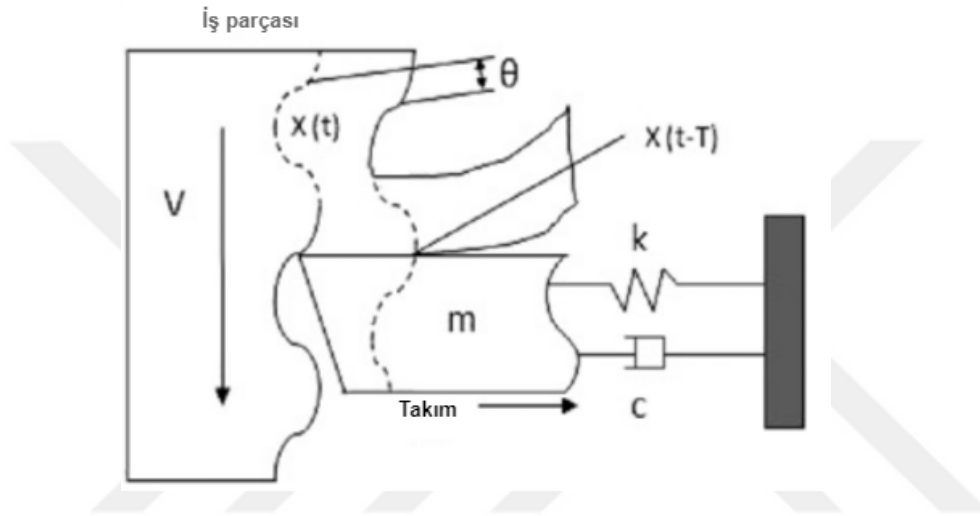
Takım tezgâhı dinamikleri kararlılık analizler ve süreç kontrolü için uzun yıllardır önemli bir konu olmuştur. Takım dinamiklerinin sürecin tırlama kararlılığı analizlerinde önemli bir etkisi vardır. Kararsızlık tahmini için hangi yöntem kullanılırsa kullanılsın, en güvenilir sonuçlar yapının dinamiği ve kesim süreci arasındaki ortaklık ile alınabilmektedir. 1990 yılları öncesinde yapılan erken tırlama araştırmaları hız, besleme ve kesme derinliğine yoğunlaşmışlardı. Fakat bu modeller takım tezgâhı dinamiklerini ifade edebilecek kabiliyette değillerdi. Bu nedenle de doğruluk oranları düşüktü. Ancak son birkaç yılda (1990'lardan sonra), diğer yeni süreç sönmülemesi, takım aşınması, takım geometrisi, makine bileşenlerinin sertliği, alet ve iş parçası dinamik modellere dahil edilmiştir. Bu yeni dinamik modeller, takım tezgâhı sisteminin gerçek dinamik doğası ve tornalamanın stabilizesini/kararsızlığını tahmin etmede daha doğru sonuçlar vermiştir.

Yenileyici tırlama titreşimleri metal kesim süreci ve tezgâh arasındaki etkileşimden doğar ve maksimum talaş kaldırma oranı için büyük bir engel teşkil etmektedir. Şekil 2.10’da tezgâh ile kesim işlemi arasındaki etkileşim modellenmiştir.

Takım parametreleri  $m$ ,  $k$  ve  $c$  sırasıyla kütle, sertlik ve sönmüleme katsayılarıdır.  $V$  ise iş parçasının kesim hızını ifade etmektedir. Burada  $x(t)$  şu anki dönüşteki dalga sayısıdır.  $x(t-T)$  ise önceki işlemde üretilmiş dalga sayısını ifade eder.



**Şekil 2.10:** Tezgâh ile kesim işlemi etkileşimi.



**Şekil 2.11:** Yenilenme mekanizması şematik gösterimi [8].


Tornalamada tırlama oluşumunu yöneten en önemli faktör bir önceki dönüşteki  $x(t-T)$  ve şu anki dönüşteki  $x(t)$  dalgalar arasındaki faz kayması ( $y$ )'dir. İki dalga aynı fazda ise ( $y=0$ ), iş parçası üzerindeki dalgalanmalar büyümeyecek ve talaş kalınlığı varyasyonu olduğu için süreç sabit kalacaktır. Tornalama sisteminde enerji transferi açısından bakıldığında, tırlamanın başlangıcı, istikrar eşiği olarak kabul edilebilir. Faz kayması olmadığında sistemde fazla enerji yoktur ve durum kararlı bir kesim ile sonuçlanır. Ancak dalgalar fazında olmadığında ( $\theta=0$ ), kesici takıma verilen enerji nedeniyle iş parçası üzerindeki dalgalanmalar büyür ve harcanan enerji, verilen enerjiden daha azdır. Bu, sonunda kararsız bir kesme işlemiyle sonuçlanır. Bu titreşimler altında talaş kalınlığı sürekli değişir ve bu da dinamik doğal modlardan birine yakın bir frekansta kesme kuvvetleri ve sistemi daha da tahrik eder. Tırlama, bu titreşimlerle ilişkili gürültüden, kesim yüzeyindeki tırlama işaretlerinden ve tornalama sırasında üretilen talaşların görünümünden tanınabilir. Tırlamalı bir şekilde talaşlı işleme, takımın ya da başka tezgâh parçalarının kırılma ihtimali olduğu

için neredeyse kabul edilebilir değildir [20]. Bunun sebebi yüzeydeki tırlama izleri ve kesme kuvvetlerindeki büyük pik değerleridir. Tırlama sınırlayıcı bir faktördür, makine kapasitesinin altında talaş kaldırma oranı ve dolayısıyla makinenin üretkenliğini azaltır.

Dinamik tırlama modeline ait parametrelerin belirlenmesi güç bir iştir. Tornalama işlemi dinamiklerini tanımlayan analitik ifadeleri formüle etmek için temel olarak iki yaklaşım vardır [12]. İlki, uygun formdaki artımlı kesme kuvveti denklemlerini belirlemek ve bu ifadelerin katsayılarının değerlerini kararlı durum kesme testlerinden [21,22] veya deneysel olarak türetilmiş kararlılık çizelgelerine fit ederek üretmek [23,24] veya ifadeleri dinamik/titreşimli kesme testlerinin sonuçlarına fit ederek olmuştur [25,26]. Çok çeşitli kesme koşullarının araştırılması gerekiyorsa, kararlı durum testlerini kullanmak çok daha basittir. Tornalama, borlama, frezeleme ve delik delme için birleşik bir matematiksel model sunulmuştur [27]. Bu genelleştirilmiş model, ISO standartlarına göre bu çoklu kesme işlemlerinin takım/kesici geometrilerini içerir ve eğik mekaniği dikkate alarak kesme kuvvetlerini tahmin eder. Model oldukça umut vericidir çünkü birden fazla operasyon için birleşik tırlama kararlılığı yasaları geliştirmek için bile kullanılabilir.

Etkili talaş açısı, boşluk açısı ve anlık kesme yönü gibi değişen kesme kuvvetlerini etkileyen bir dizi parametre vardır. Ancak dinamik kuvvetleri en çok etkileyen faktörleri belirlemek için, metal kesmenin temel mekaniğinin dikkate alındığı ve Meritt [15] tarafından türetilen kesme işlemi modeline dayanan titreşimli torna sürecini tanımlayan ikinci bir yaklaşım bulunmaktadır. Bu ikinci yaklaşımda, kesme kuvveti değişimleri, takımın çevrimsel hareketi sırasında herhangi bir noktadaki toplam kuvvet dikkate alınarak ve kesme parametrelerinin ve takım geometrisinin anlık değerlerine tekabül edecek şekilde belirlenir. Bu ikinci yaklaşıma dayalı olarak, tırlama işleminin tam dinamiklerini ve tornalama işleminin tırlama kararlılık tahminini temsil eden bir matematiksel model formüle edilmiştir.

Esnek bir alet ve nispeten rijit iş parçası ile tek serbestlik dereceli ortogonal tornalama işlemini dikkate alan matematiksel bir model Şekil 2.12'de gösterilmiştir. Model, atalet kuvveti, sönüm kuvveti, yay kuvveti ve kesme kuvveti gibi fiziksel sisteme etki eden çeşitli kuvvetleri içermektedir.



**Şekil 2.1:** Tek serbestlik dereceli ortogonal tornalama modeli [8].

Yukarıda tanımlanmış esnek takım rijit bir iş parçasını keserken dinamik istemin radyal yöndeki hareket denklemi şu şekilde modellenebilir:

$$m\ddot{x}(t) + c\dot{x}(t) + kx(t) = F_f(t) \quad (2.5)$$

Burada  $F_f(t)$ , x besleme yönündeki kesme kuvvetidir.

$$F_f(t) = K_f * b * [x(t - T) - x(t)] \quad (2.6)$$

$K_f$  besleme yönündeki kesme sabiti, b talaş genişliği, T bir önceki zaman ile şu an arasındaki zaman gecikmesi ve  $[x(t - T) - x(t)]$  ise takım titreşiminden kaynaklanan talaş kalınlığıdır.

$$\ddot{x} + \frac{c}{m}\dot{x} + \frac{k}{m}x = \frac{K_f b}{k} \frac{k}{m} [x(t - T) - x(t)] \quad (2.7)$$

Laplace dönüşümü uygulanıp bazı ilişkiler kullanılırsa;

$$\omega_n^2 = \frac{k}{m}, \quad \frac{c}{m} = 2\zeta\omega_n \quad \text{ve} \quad \varphi = \frac{K_f b}{k} \quad \text{olduğunu varsayarsak} \quad (2.8)$$

$$s^2 + 2\zeta\omega_n s + \omega_n^2 = \varphi\omega_n^2(e^{-sT} - 1) \quad (2.9)$$

Sistemin transfer fonksiyonu Denklem 2.9'dan elde edilebilir;

$$\Gamma(s) = \frac{1}{s^2 + 2\zeta\omega_n s + \omega_n^2} \quad (2.10)$$

$S=jw$ , Denklem 2.10'da yerine yazılırsa (w tırlama frekansdır), transfer fonksiyonun gerçek ve imajiner bölümleri aşağıdaki gibi olur;

$$G(\omega) = \frac{\omega_n^2 - \omega^2}{R(\omega)} \text{ (gerçek kısım)} \quad (2.11)$$

$$H(\omega) = \frac{-(2\zeta\omega_n)\omega}{R(\omega)} \text{ (imaşiner kısım)} \quad (2.12)$$

Burada  $\omega_n$  sistemin doğal frekansdır,  $\omega$  ise tırlama frekansdır.

Tornalama işleminin sınırlayıcı kesme genişliği kararlıdan kararsıza geçişler ilişki ile bulunabilir [28]:

$$b_{lim} = -\frac{1}{2K_f G(\omega)} \quad (2.13)$$

Kararlılık denklemi sadece, takım ile iş parçası arasındaki transfer fonksiyonunun gerçek kısmı  $G(\omega)$  negatif olduğunda pozitif bir gerçek kesme derinliğine yol açar. Denklem 2.13 yalnızca  $G(\omega)$ 'nin en küçük değeri negatif olduğunda mutlak bir kesme derinliği verir.

Faz açısı bu şekilde tanımlanacak olursa;

$$\psi = \tan^{-1} \frac{H(j\omega)}{G(j\omega)} \quad (2.14)$$

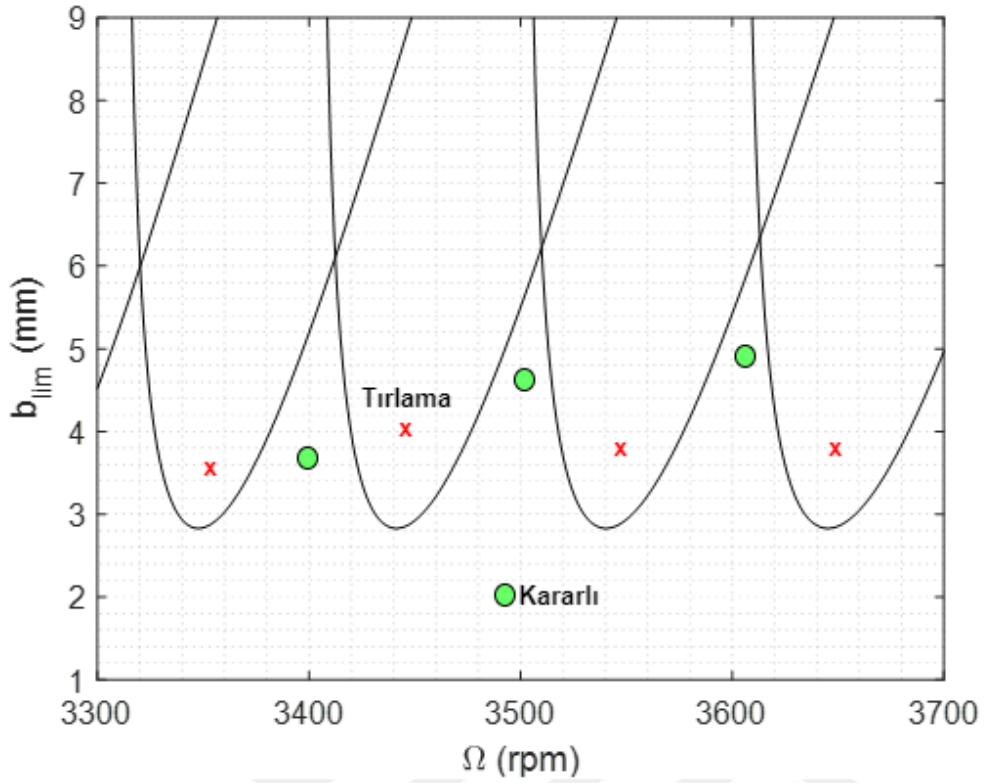
Ve bazı manipülasyonlar yapıldığında iş mili periyodu  $T$  ve faz kayması  $\theta$  aşağıdaki gibi elde edilir,

$$T = \frac{1}{\omega} [2n\pi + \theta], \theta = 3\pi + 2\psi \quad (2.15)$$

İş mili hızı ise belirtilen denklem ile elde edilir:

$$\Omega = 60/T \quad (2.16)$$

Denklemler 2.14 – 2.16, Şekil 2.13'te gösterildiği gibi tornalama işlemi için sınır kesme genişliği  $b_{lim}$  ve iş mili hızı  $\Omega$  arasındaki ilişkiyi gösteren stabilite lobları diyagramını (SLD) oluşturmak için kullanılabilir.



**Şekil 2.13:** Çeşitli hızlar ve kesme genişlikleri için stabilite loblarını/bölgelerini gösteren bir SLD.

Tırlama SLD'leri, gerçek kısmın negatif olduğu, örneğin  $G(w) < 0$  gibi transfer fonksiyonundan olası tırlama frekanslarının taranmasıyla oluşturulur. SLD, kesme genişliği ve iş mili hızının farklı kombinasyonları için kararlı (gecikmesiz) ve kararsız kesme işlemi bölgelerini ayırt eder. Stabilite lobları altında kesme genişliği ve iş mili hızı seçildiğinde, süreç stabil olacak ve bu da pürüzsüz bir yüzey kalitesine ve takım tezgâhı sistemi üzerinde daha az dinamik yüklere yol açacaktır [28]. Kesim genişliği ve iş mili hızının belirli kombinasyonlarını seçerek, baştan sona istikrarlı bir tornalama işlemi elde etmek için tırlama titreşimlerinden kaçınılabilir.

Darbe çekiç testi, tırlama modeli için dinamik parametreler elde etmek için en geleneksel deneysel yöntemdir. Özellikle, transfer fonksiyonunun doğal frekansı, sönüm oranı, gerçek ve imajiner kısımları, birçok araştırmacı tarafından kullanılan darbe testi tekniği ile belirlenmektedir [29]. Takım-iş parçası sisteminin yapısal rijitliği  $k$ , ise takım aracılığıyla iş parçasının ucuna uygulanan yer değiştirme ve statik kuvvetin eş zamanlı ölçümü ile elde edilebilir.

## 2.5 Tornalamadaki Tırlamanın Analitik Tahmin Yöntemleri

Tırlama kararlılık koşullarının analitik tahmini için literatürde çeşitli teknikler mevcuttur. SLD, Nyquist grafikleri ve sonlu elemanlar yöntemi literatürde en sık kullanılan tekniklerdir. SLD bu yöntemler arasında en sıklıkla kullanılan ve en popüler olanıdır. SLD inşasının diğer yöntemlere göre daha fazla tercih edilmesinin ana sebepleri anlaşılabilirliği ve basite indirgenebilirliğidir. SLD serbestlik derecesi fark etmeksizin tüm kesim prosesleri için uygulanabilmektedir.

### 2.5.1 Stabillite lob diyagramları

Bir tornalama işleminde tırlama oluşumu için belirleyici olan en önemli kesme parametresi kesme derinliğidir (talaş genişliği)  $b$ . Talaş genişliği daha küçük olduğunda kesme işlemi daha kararlıdır. Talaş genişliğini artırarak, belirli bir talaş genişliğindeki boşlukta  $b_{lim}$  (sınırlayıcı kesme derinliği) tırlama oluşmaya başlar ve tüm  $b > b_{lim}$  değerleri için daha enerjik hale gelir. Bu nedenle  $b_{lim}$ , kesme stabilitesi için en önemli parametredir.  $b_{lim}$  değeri yapının dinamik özelliklerine, iş parçası malzemesine, kesme hızına ve ilerlemeye ve takımın geometrisine bağlıdır [29]. SLD, bir tornalama işleminde tırlama kararlılığının tahmini için kullanılabilir. Kesme boşluğunun sınırlayıcı derinliği, Şekil 16'da benzer tipik bir çizimde gösterildiği gibi SLD üzerindeki iş mili hızına (N) karşı çizilir. Takım ve iş parçası arasındaki titreşimler farklı loblar ( $n=1, 2, 3, y$ ) olarak görünür ve bu lobların altına düşen talaş derinliği ve iş mili hızı kombinasyonu, kararlı (tırlamasız) bir çalışma ile ve bu lobların üzerinde, kararsız (tırlama) bir çalışma ile sonuçlanır. SLD'lerin yardımıyla, bir tornalama işleminde maksimum talaş kaldırma oranı için ideal iş mili hızı ve kesme derinliği kombinasyonlarını seçmek oldukça kolaydır.

Meritt kesme derinliği ve iş mili hızı gibi işlem parametreleri açısından tırlamayı tahmin etmenin mümkün olduğu stabilite çizelgeleri aracılığıyla stabilite koşullarını sunmuştur [15]. Bu önemli bir katkıydı çünkü uygun süreç parametrelerinin seçilmesiyle talaş kaldırmadan talaş kaldırma oranında bir iyileşme sağlamıştır. Das ve Tobias ve Tlustý tarafından sunulan lineer tırlama kararlılık modelleri, anlık, yenileyici talaş kalınlığının dinamik kuvvet üzerindeki etkilerini dikkate almıştır [21,31]. Burada sunulan kararlılık modelleri, tam talaş oluşum sürecini

içermemekteydi. Bununla birlikte, Tlusty tarafından oluşturulan ve yönetilen CIRP grubu, tornalama ve diğer işlemlerdeki tırlamanın, talaş oluşum sürecinin negatif sönümlenmesinden değil, takım tezgâhı ve kesme arasındaki kuvvet-yer değiştirme etkileşiminden kaynaklanan kendinden tahrikli titreşimlerden kaynaklandığını bulmuşlardır.

Geri besleme sistemi kazancına veya talaş genişliği  $b$  ve iş mili hızına  $\Omega$  bağlı olarak, tornalama işlemi ya kararlı olacaktır ya da büyük titreşimlere ve kuvvetlere neden olan ve kötü yüzey kalitesine, alet/iş parçası hasarına neden olan tırlama durumu sergileyecektir. Kararlı işlemede, titreşimler devirden devire azalır. Kararsız işlemede ise titreşimler bir şekilde sınırlanana kadar devirden devire büyür. Titreşimler, aletin iş parçasıyla teması keserek kesimden dışarı fırlamasına yetecek kadar büyüyebilir. Kararsız kesimdeki titreşimler en az talaş kalınlığı kadar büyük olabilir ve bu büyük titreşimlerin makineye, takıma ve iş parçasına zarar vermesi şaşırtıcı değildir. Bu davranış için yönetim ilişkileri Denklemler 2.17-2.19'da verilmiştir [30].

$$b_{lim} = \frac{-1}{2K_s \cos(\beta) \text{Re} [\text{FRF}]} \quad (2.17)$$

$$\frac{f_c}{\Omega} = N + \frac{\varepsilon}{2\pi} \quad (2.18)$$

$$\varepsilon = 2\pi - 2 \tan^{-1} \left( \frac{\text{Re} [\text{FRF}]}{\text{Im} [\text{FRF}]} \right) \quad (2.19)$$

Burada  $b_{lim}$  kritik kesme genişliğidir,  $K_s$  iş parçasının malzemesine bağlı katsayıdır,  $\beta$  kuvvet açısıdır,  $f_c$  tırlama frekansdır,  $w$  iş mili hızıdır,  $N$  lob sayısıdır,  $\frac{\varepsilon}{2\pi}$  bir dalgaın kesridir ve mevcut ve önceki takımın titreşimleri arasındaki faz  $\varepsilon$ 'dur. Ortak sınırın üzerinde görünen herhangi bir " $\Omega, b_{lim}$ " çifti kararsız davranışı gösterirken, sınırın altındaki herhangi bir çiftin kararlı olduğu varsayılır.

## 2.6 Tırlama Stabilitesi Tahmini ve Tırlama Tespiti İçin Deneysel Teknikler

Üretim maliyetlerini düşürme talebinin artması nedeniyle, gözetimsiz işleme, imalat sanayilerinin çoğunda önemli bir özelliktir. Bu nedenle, insansız tornalama işleminde, yüzey bütünlüğü üzerindeki zararlı etkilerden ve büyük genlikli



titreşimlerden kaynaklanan katastrofik takım arızasından kaynaklanan iş parçası veya takım tezgahlarında hasardan kaçınmak için rejeneratif tırlamanın otomatik tespiti çok önemlidir. Deneysel teknikler, çevrim dışı modda kararlılık durumunu tahmin etmede ve çevrim içi modda tırlama başlangıcını tespit etmede faydalıdır. Bu deneysel tekniklerin insansız bir işleme ortamı oluşturma potansiyeli vardır. Bazı deneysel teknikler, modal test yoluyla elde edilen takım-iş parçası sisteminin modal parametreleri yardımıyla sistemin SLD'sini üreterek tırlama stabilitesi tahmini için çevrimdışı olarak kullanılır. Ancak, bu SLD yarı analitik olacaktır. Gerçek/gerçekçi bir SLD daha çok gerçek kesme testleri yardımıyla elde edilir, ancak doğrudan kesme testi ile SLD elde etme görevi çok zaman alıcıdır. Deneysel doğrulama/doğrulama, tırlama stabilitesi tahmin modelinden elde edilen teorik tırlama başlangıç koşulları ile karşılaştırmalara dayalı olarak ve kesme işleminde tırlama başlangıcını tanımlayarak belirli bir işlemin kararlı olup olmadığını bilmek için zorunludur. Bu tanımlama, takım durumu izleme (TCM) teknikleri kullanılarak mümkündür.

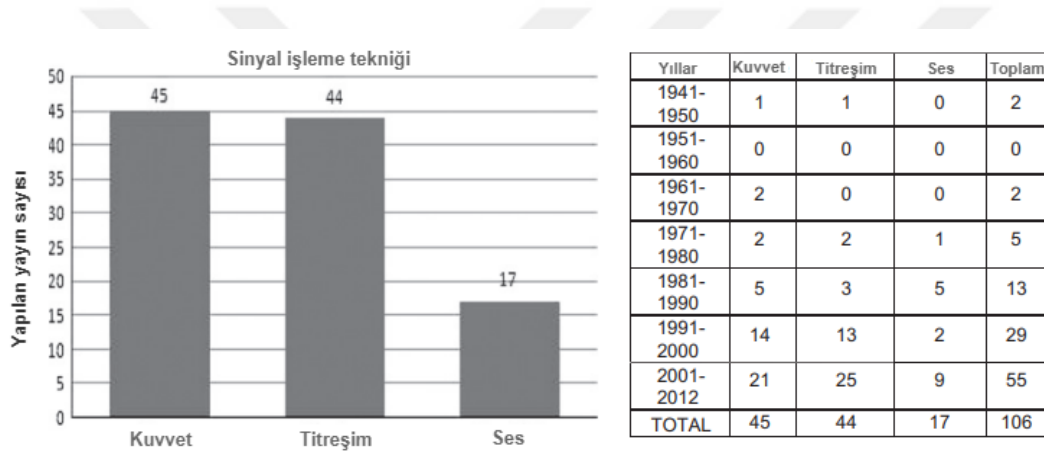
Deneysel teknikler, tırlama stabilitesi tahmini ve tırlama doğrulaması (tespiti) için kullanılan tekniklere dayalı olarak bu bölümde sınıflandırılmıştır. Şekil 2, sinyal işleme, talaş analizi ve yapay zekâ yöntemleri gibi en sık kullanılan deneysel teknikler için yayın sayısı hakkında bilgi vermektedir. Herhangi bir takım tezgâhı için durum izleme sistemi mutlaka özel olarak inşa edilmiştir ve bu nedenle Siddhpura vd. tarafından açıklanan takım tezgahının tipine bağlıdır [32]. Takım durumunun izlenmesi, sürecin izlenmesi için çok faydalı olan kuvvet, titreşim ve akustik sinyaller kullanılarak gerçekleştirilebilir. Belirli bir takım ve iş malzemesi çifti için bir ortogonal kesme veri tabanı oluşturmak için bir dizi kesme ortogonal kesme testleri (kesme hızı, eğim açısı ve kesilmemiş talaş kalınlığı için tekrarlanan) yapılmıştır [33,34]. Bu teknikler aşağıda kategorize edilmiştir:

- Sinyal toplama ve işleme
  - Kuvvet ve titreşim ölçümleri
  - Ses ve akustik emisyon ölçümleri
- Talaş analizi teknikleri

- Yapay zekâ teknikleri

### 2.6.1 Sinyal toplama ve işleme

Bir işleme sürecinden üretilen kuvvet, yer değiştirme, hız, ivme ve akustik sinyalleri ölçebilen çeşitli sensörler ile tahmin edilen tırlama kararlılığının doğrulanması ve tespiti mümkündür. Yukarıdaki sinyalleri elde etmek ve sinyal toplama sisteminin bir parçası olmak için çeşitli sensörler kullanılır. Şekil 2.14, bu sinyal toplama tekniklerinin her biri için yayın sayısı hakkında bilgi sağlar. Ardından, sensörler aracılığıyla alınan sinyallerden faydalı bilgiler elde etmek için sinyal işleme gerçekleştirilir. Zaman alanı, frekans alanı ve zaman–frekans alanı analizi gibi geleneksel sinyal işleme teknikleri genellikle araştırılır.



**Şekil 2.14:** 1946-2012 yılları arasında sinyal toplama tekniklerini içeren yayın sayısı grafiği ve seçilen yayınların özetini gösteren tablo [1].

Tlusty ve Andrews insansız bir işleme merkezi geliştirmek için birkaç sensörü ve bunların tırlama tespiti, işleme süreçlerinde takım kırılması tespiti için yeteneklerini incelenmiştir [35]. Tornalama ve frezeleme için kuvvet, titreşim ve akustik sensörler test edilmiştir. Titreşim sinyallerine kıyasla tırlama tespiti için kuvvet sinyallerinin en iyi sinyaller olduğu bulundu. Tırlama takım ve iş parçası arasındaki göreceli bir titreşim olduğundan ve bu nedenle bir titreşim dönüştürücü ile ölçülmesi zor olduğundan, kesme kuvveti takım ve iş parçası arasındaki bağıl titreşimin doğrudan bir göstergesidir ve çok karakteristik kuvvet değişimi modelleri onu tırlamayı açıkça ayırt etmek mümkün kılmaktadır.

Heyns bu sinyal işleme tekniklerini gözden geçirdi ve zaman alanı ve frekans alanı yöntemlerinin takım aşınması ve tırlama tahmini için yaygın olarak kullanıldığını

bulmuştur [36]. Ancak dalgacık dönüşümü gibi zaman-frekans alanı yöntemleri, henüz tamamen kullanılmamış olan daha yüksek yeteneklere sahiptir. Zhu vd. zaman alanı yöntemlerinin takım durumu izlemede en yaygın olarak kullanıldığını, ancak bu yöntemlerin zaman alanında bazı sinyal bilgilerini kaybettiğini savunmuştur [37]. Hızlı Fourier dönüşümü (FFT) ve dalgacık dönüşümü karşılaştırılmış ve kısıtlılığı ve lokalizasyon özellikleri nedeniyle dalgacık dönüşümünün FFT'den çok daha etkili olduğu bulunmuştur. Dalgacık dönüşümü, zaman yerelleştirilmiş bir şekilde frekans bilgisi verir. Dalgacık dönüşümü, takım durumu izlemedeki takım koşullarındaki ani değişiklikleri tespit etmede büyük potansiyele sahiptir. Sağlamdır ve değişen çalışma koşullarına karşı duyarsızdır.

### **2.6.1.1 Kuvvet ve titreşim ölçümü**

Kuvvet ve titreşim sinyalleri, kesme sürecinin dinamikleri hakkında kapsamlı bilgi sağladıkları ve işleme proseslerinin durum izlemede çok faydalı oldukları için araştırmacıların çoğu tarafından tercih edilmektedir. Kuvvet ve titreşim ölçüm tekniği, kesme kuvvetleri, titreşimler ve tırlamaya neden olan mekanizmalar arasındaki karmaşık ilişkiden dolayı, yenileyici tırlamanın tespit edilmesinde en yaygın kullanılan tekniklerden biridir. Kuvvet ve titreşim ölçümlerinden gerekli sinyalleri elde etmek için farklı sinyal işleme teknikleri kullanılmaktadır. Shanker darbe testi ve titreşim ölçümleriyle eğik tornalama için esnek bir iş parçası ile iki serbestlik dereceli tırlama stabilite tahmin modelini doğruladı [38]. İş parçasının doğal frekansı ve sistem sönümü, uzunlukları boyunca birkaç noktada uyarılarak ve bir rezonans eğrisi elde edilerek belirlenmiştir. Tırlama frekansı, takım sapına monte edilmiş bir titreşim alıcısı tarafından kaydedilmiştir. Takım geometrisinin kararlılık sınırı üzerinde çok az etkisi olduğu, ancak kararlılığın iş parçasının boyutları ve uyumundan önemli ölçüde etkilendiği öne sürülmüştür.


Rahman ve Ito girdap akımı tipi yer değiştirme alıcılarını kullanarak iş parçasının yatay sapmasını çevrimiçi olarak ölçerek, tırlama başlangıcını belirlemek için bir yöntem sunmuştur [39]. Kesme kuvvetlerinin proses içi ölçümü için bir piezoelektrik tip üç bileşenli dinamometre kullanmıştır. İş parçası sapmasını ölçmeye yönelik bu teknik uyumlu takım-iş parçası modellerini doğrulamak için oldukça faydalı olmuştur. Bao vd. titreşim sinyallerinin tırlamadan önceki ve sonraki olasılık yoğunluk fonksiyonunun dağılımları arasındaki temel farkı ayırt etmiştir ve bu,

tornalamadaki tırlamanın tespit edilmesi için kullanılmıştır [40]. Erken tırlama stabilitesi tahmini için bir parametre olarak dinamik kesme kuvvetinin genlik alanındaki aralık frekans farkı 'H'yi seçmişlerdir. Bu tahmin parametresi, dinamik sinyalin olasılık yoğunluk fonksiyonundan elde edilmiştir. Göreceli bir değer olduğu ve daha yüksek tahmin doğruluğuna sahip olduğu için kesme koşullarından da etkilenmemiştir. Kararlı durum ve tırlama durumu arasındaki süreç tarafından tanımlanan geçiş durumunun, rastgele sinyal ve sinüs sinyalinin karmaşık kombinasyonu olduğu varsayılmıştır. Tırlama tanıma sisteminde özellik çıkarımı ile yeni bir teknik olmasına rağmen, kesme durumu tanımlaması için bir model sınıflandırıcı gerekmektedir.

Yeh ve Lai, ince bir iş parçasını tornalamak için bir tırlama izleme ve sinyal işleme sistemi geliştirmiştir. İzlemede kesme kuvvetinin dinamik bileşeni tespit edilmiş ve sinyal işleme yoluyla standart sapma değeri  $s$  hesaplanmıştır [41]. Tırlama oluşumu,  $s$  değerinin dik artışı kullanılarak değerlendirilmiştir. Lin ve Hu gibi basit bir eşik seçmek yerine, tırlama tespitinde yanlış yargılardan kaçınmak için eşik seçimi için çifte standartlı bir konsept önermiştir [42]. Takım ucu akıntısının kesme kuvvetini ve işleme sürecinin performansını etkileyeceğinden de bahsedilmiştir.

### 2.6.2 Talaş analizi tekniği

Bazı araştırmacılar, stabilite koşullarını belirlemek ve tırlama oluşumunu tespit etmek için bir tornalama işleminde üretilen talaşları analiz etmişlerdir. Şekil 2.15'te bir talaş örneğinin mikroskop altındaki görüntüsü gösterilmiştir.



**Şekil 2.15:** Torna işlemi sırasında ortaya çıkmış bir talaş örneğinin mikroskop altındaki görüntüsü.

Nurulamin tam kararsızlık döngüsünün farklı fazlarında kesme işlemini anında durdurarak alınan talaş köklerinin mikro kesitli metalografik örneklerinde ve ayrıca talaşın mikro kesitli metalografik örneklerinde talaş oluşumunun kararsızlık mekanizmasını incelemiştir [43]. Bu tür örnekler üzerinde metalografik mikroskop ve mikro sertlik ölçüm cihazları yardımıyla tane yönü, farklı bölgelerin sınırları ve mikro sertlik ölçülmüş ve bunlara göre kayma açısı, farklı bölgelerin uzunlukları ve temas alanları ve ayrıca döngünün her aşamasının zamanı belirlenmiştir. Tırlamanın fiziksel nedeninin, talaş oluşumunun kararsızlığı ve rezonans frekansında takım ile iş parçası arasındaki kendi kendine uyarılma olduğu keşfedilmiştir.

Tangjitsitcharoen bir CNC torna tezgâhı için proses içi izleme ve kesme durumlarının tanımlanması için bir yöntem sunmuştur [44,45]. Yöntem, dinamik kesme kuvvetinin güç spektrum yoğunluğunu kullanmaktadır. Deneysel sonuçlar, kesme durumları sürekli talaş oluşumu, kırık talaş oluşumu ve tırlama olduğunda üç tip güç spektrum yoğunluğunu modeli olduğunu keşfetmiştir. Kararlı ve güvenilir bir çalışma için kırık talaş oluşumu istenmektedir. Sürekli talaş oluşumu sırasında, frekans 50 Hz'den az olduğunda dinamik besleme kuvveti küçük ve güç spektrum yoğunluğunu büyüktü. Kırık talaş oluşumu sırasında, talaş kırma frekansında büyük güç spektrum yoğunluğunu ile büyük değişken dinamik besleme kuvveti gözlemlendi. Ve tırlama meydana geldiğinde, elde edilen güç spektrum yoğunluğunu, sürekli ve kırık talaş oluşumlarından daha büyüktü.

Patwari vd. taramalı elektron mikroskobu kullanarak talaşların üstten ve kesit görüşlerini gözlemlemiştir ve tornalama ve diş açma sırasında üretilen talaşların, talaşın serbest kenarı boyunca aynı düzenli aralıklı tırtıklı dişler sergilediğini gözlemlemiştir [46]. Tırlama genliklerini analiz ettikten sonra, yonga tırtıklı frekansı sistem bileşenlerinin belirgin doğal frekansına eşit veya bunun bir tamsayı katı olduğunda sistemde tırlamanın ortaya çıktığı da bulunmuştur.

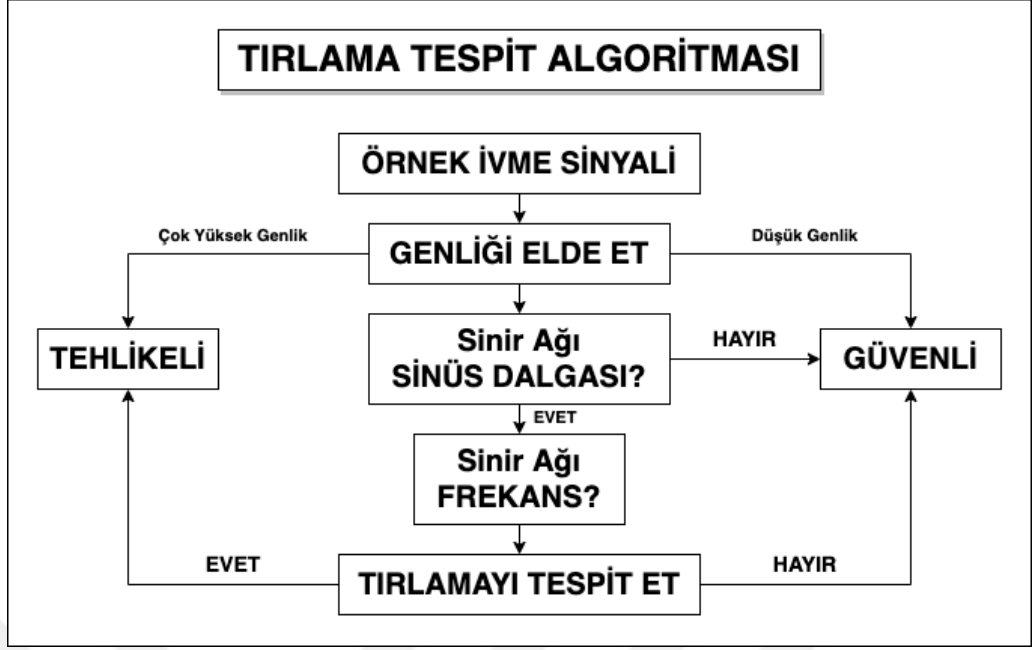
Nurulamin vd. tornalama, diş açma ve frezeleme işlemlerinde oluşan talaşların, ikincil testere dişleri şeklinde ortak bir ayrıklık gösterdiğini belirlemiştir [47]. Birincil testere dişleri, ikincil testere dişleri ve frekansları dışında tanımlanmıştır. Yongalar, SEM, optik mikroskop ve bir dijital kamera kullanılarak incelenmiştir. Talaş oluşumunun, ikincil testere dişlerinin, birincil testere dişlerinin ve iki bitişik ikincil testere dişi arasındaki sınırdaki çatlakların oluşmasından dolayı kararsız olduğu

bulunmuştur. Talaş oluşumu kararsızlığının frekansı, bir tormalama işleminde sistem bileşenlerinin öne çıkan doğal frekanslarının yaklaşık olarak bir tamsayı katına eşit veya bir tamsayı katına ulaştığında sistemde tırlama ortaya çıkmıştır. Takım tutucu, tormalama sürecindeki tırlamadan sorumlu olan önde gelen sistem bileşeniydi. Bazı araştırmacılar hala talaş oluşumunu tormalama işleminin dinamikleri ve tırlama koşullarına karar vermekle ilişkilendirmektedir. Ancak talaş analizi, sürecin kararlılığını önceden tahmin edemediği için yalnızca sürecin/davranışın analizi olarak kalmıştır.

### 2.6.3 Yapay zekâ teknikleri

Sensör sinyalleri yoluyla elde edilen sinyal özelliklerini sınıflandırarak gevezelik oluşumunu tahmin etmek ve tespit etmek için ANN, gizli Markov modeli (HMM) ve bulanık mantık gibi yapay zekâ teknikleri sunulmuştur. Bu yapay zekâ teknikleri bu bölümde incelenecektir.

ANN, beyinin işleme bilgisi gibi biyolojik sinir sistemlerinden ilham alan bir bilgi işleme modelidir. Bu modelin temel unsuru, bilgi işleme sisteminin kendine has yapısıdır. Belirli sorunları çözmek için uyum içinde çalışan çok sayıda birbirine bağlı işlem elemanından (nöron) oluşur. ANN, bir öğrenme süreci yoluyla örüntü tanıma veya sinyal özelliklerinin veri sınıflandırması gibi uygulamalar için kullanılabilir. Tansel vd. sinir ağını kullanarak tırlama gelişimini tahmin etmek için tek sensörden elde edilmiş bir girdi veri seti kullanmıştır [48]. Önerilen yöntem, harmonik sinyallerin %98'ini sadece %5 hata ile başarıyla tanımlamıştır. Tırlama sinyalleri, iki çok katmanlı algılayıcı tabanlı sinir ağı mimarisine girdi olarak verilmiştir. Biri sistem harmoniklerini tanımlamıştır, diğeri ise titreşimi tahmin etmek, ivme sinyallerini analiz etmek için ve frekansı tahmin etmek için kullanılmıştır. Bu iki ayrı prosedürü birleştirmek için, tırlamayı ve frekansını belirlemek için bir algoritma geliştirmiştir. Test, bir fonksiyon üretici kullanılarak ve tormalama işleminde çevrim içi test ile gerçekleştirilmiştir, burada kararsız titreşimleri algılayabildi ve sonuç olarak önemli takım ömrü tasarrufu sağlayabildi. Orijinal makaledeki, önerilen tırlama tahmini algoritmasına ait akış diyagramı Şekil 2.16'da gösterilmiştir.



**Şekil 2.16:** Tırlama oluşumu tahmin prosedürü algoritması [48].

HMM de tırlama tanıma için yaygın olarak kullanılmaktadır. Dinamik zaman serilerini modellemek için çok uygundur ve sensör sinyallerinden alınan bol bilgiden örüntü tanıma için güçlü bir yeteneğe sahiptir. Zhang vd. bir tornalama işleminde tırlama izleme için yeni bir hibrit HMM–ANN tekniği sunmuştur [49]. Hibrit HMM ve ANN, durağan olmayan bir tornalama sürecini izlemek için HMM sıralı modelleme yapısı ve ANN model sınıflandırmasının avantajlarını bir araya getirmiştir. HMM, tırlama titreşiminin izlenmesi için çok uygundur, ancak daha çok takım aşınmasını tespit etmek için kullanılmış ve tırlamayı tespit etmek için nadiren kullanılmıştır.

Bulanık mantık, beynimiz gibi bilgileri işleyebilir. Bulanık mantık sistemleri kararlarını, bir değer ait olduğu bulanık kümeyi ve Bojja tarafından açıklandığı gibi bu kümedeki üyelik derecesini belirlemek için kullanılan formüller olan üyelik işlevlerinden türetilen dilsel değişkenler biçimindeki girdilere dayandırır [50]. Bu değişkenler daha sonra bulanık mantık kuralları olarak adlandırılan dilsel IF-THEN kurallarının ön koşullarıyla eşleştirilir ve her kuralın yanıtı bulanık çıkarım yoluyla elde edilir. Du vd. ilk olarak Zadeh tarafından tanıtılan bulanık küme teorisini kullanarak tornalamada takım durumu izleme üzerine bir çalışma sunmuştur [51,52]. Takım tırlaması, kırılma, takım aşınması gibi takım koşulları dikkate almıştır. Kuvvet, titreşim ve güç sensörlerini takip etmiştir. Doğrusal bulanık yöntem, K-

ortalama, Fisher örüntü tanıma yöntemleri ve bulanık C-ortalama yöntemi dâhil olmak üzere çeşitli sınıflandırma şemaları ile karşılaştırmıştır ve önerilen bulanık yöntemden elde edilen sonuçların, araç koşullarını tespit etmek için genel olarak %90'lık bir güvenilirlik gösterdiği göstermiştir.

## 2.7 Sinyal Ayırıştırma Metotları ve CEEMDAN

Sinyal ayırıştırma yöntemlerini kullanarak, kesme sinyalini değerlendirme yaklaşımı genellikle benzerdir. Sinyal önce bir dönüşüm algoritması kullanılarak bileşenlerine ayrıştırılır. Ardından, yeni bir sinyali yeniden oluşturmak için, tırlama ile ilgili önemli bilgileri içeren sinyalin ayırıştırılmış bölümleri seçilir. Bu bileşenler, tüm parçalar üzerinde FFT gerçekleştirerek ve sistemin bilinen doğal frekanslarıyla örtüşenleri seçerek seçilir. Son olarak, bu sinyal bileşenleri farklı karakteristikleri hesaplamak için kullanılır. Tırlama tanımlama yaklaşımlarının çoğu ses, vibrasyon veya kuvvet verilerinden özellik çıkarmaya ve bunları önceden belirlenmiş tırlama işaretleriyle ilişkilendirmeye odaklanır [53,54,55]. En yaygın olarak kullanılan teknikler EEMD, VMD, WPT ve CEEMD'dir [56,57,58,59].

EMD, bir dizi IMF oluşturan uyarlanabilir bir veri analizi yaklaşımıdır. Hem doğrusal olmayan hem de durağan olmayan sistemleri incelemek için kullanılabilir. Herhangi bir karmaşık sinyali sonlu ve sıklıkla küçük bir IMF kümesine ayırıştırır ve iyi Hilbert dönüşümlerine izin veren EMD yaklaşımı, tekniğin en önemli kısmıdır [60]. Öte yandan, EMD önemli bir dezavantaja sahiptir: sıklıkla mod karıştırma sergiler, bu da bir IMF ya çok farklı ölçeklerin sinyallerini ya da farklı IMF'de yer alan karşılaştırılabilir ölçeklerin sinyallerini içerdiği anlamına gelir [61]. Gürültü destekli veri analizi yaklaşımı EEMD ise öznel bir kesinti testi gerektirmeden ölçek ayrımı sorununu ele almak için geliştirilmiştir. Gerçek IMF'ler, her biri sinyal artı sınırlı genlikli beyaz gürültü içeren bir dizi testin ortalaması olarak tanımlanır. Ek beyaz gürültü, çeşitli ölçeklerin kurucu bileşenleri ile tüm zaman-frekans alanını eşit olarak meşgul edecektir. Bu beyaz gürültü arka planına sinyal eklendiğinde bitleri gürültü seviyesine bağlı olarak uygun referans ölçeklerine otomatik olarak yansıtılacaktır. EEMD gürültü destekli yaklaşım sadece mod karıştırma sorununu çözmekle kalmamış, aynı zamanda yeni bir sorun da yaratmıştır. EEMD sinyal rekonstrüksiyonunda artık gürültüyü tolere edememektedir. İstenmeyen ve artık gürültünün önemli bir kısmı zaman alıcı uygulamalarla giderilebilir, ancak bu etkili



bir çözüm değildir [62]. İyileştirilmiş bir algoritma olarak CEEMD adlı gürültüyle geliştirilmiş bir veri analizi yaklaşımı önerilmiştir. Pozitif ve negatif eklenmiş beyaz gürültüler içeren tamamlayıcı IMF kümeleri kullanılarak, veri ve beyaz gürültü karışımlarından artık beyaz gürültüler elde edilebilir. Bu yeni yöntemin, EEMD ile aynı RMS gürültüyle IMF üretmesine rağmen, IMF'deki artık gürültüyü verimli bir şekilde ortadan kaldırır.

Bir algoritmanın hesaplama hızı, performans için önemli bir ölçüdür. Bu gereksiz IMF'lerin miktarını azaltarak ayrıştırma algoritmalarının hesaplama verimliliğini artırmak faydalıdır. Bu nedenle performans iyileştirmeleri için yeni teknikler aranmıştır. Belirtilen diğer yöntemlerden daha iyi performans gösteren CEEMDAN oluşturulmuştur [63]. CEEMDAN algoritmasının ayrıştırma adımları için südo kod, Algoritma 1'de gösterilmiştir. Südo kodda görülebileceği gibi, CEEMDAN algoritması, ilk modu, ardından ilk kalıntıyı, ardından ikinci modu ve son olarak kalan kalıntıları ve modları üretecek şekilde bir diziyi takip eder.

Bir algoritmanın hesaplama miktarı önemli bir performans indeksidir. Şekiller 2.17 ve Şekil 2.18'de gösterildiği gibi, EMD ve EEMD'de bu algoritmaların performansını düşüren bazı işe yaramaz IMF'ler üretilir. Bu nedenle, bu işe yaramaz IMF'lerin sayısını azaltmak, bu tekniklerin hesaplama verimliliğini artırmak için avantajlıdır. Torres CEEMDAN algoritmasını önermiştir ve Colominas CEEMDAN'in geliştirilmiş bir versiyonunu önermiştir [63,64]. İki algoritmayı kullanarak bir sinyalin farklı bileşenlerini başarıyla ayırma öncülünde daha az IMF üretilebilir, bu da hesaplama maliyetini azaltabilir.

Aynı sinyali ayrıştırırken EMD, EEMD ve CEEMDAN'nin çıkardığı IMF'lerin karşılaştırılması Şekil 2.19'da gösterilmiştir. Görüldüğü üzere CEEMDAN daha az IMF çıkararak EEMD ile benzer sonuçlar elde etmiştir. Aynı zamanda, EMD'de yaşanmış iki modun iç içe geçmesi problemi olan mod çarpışması problemine sebep olmamıştır.

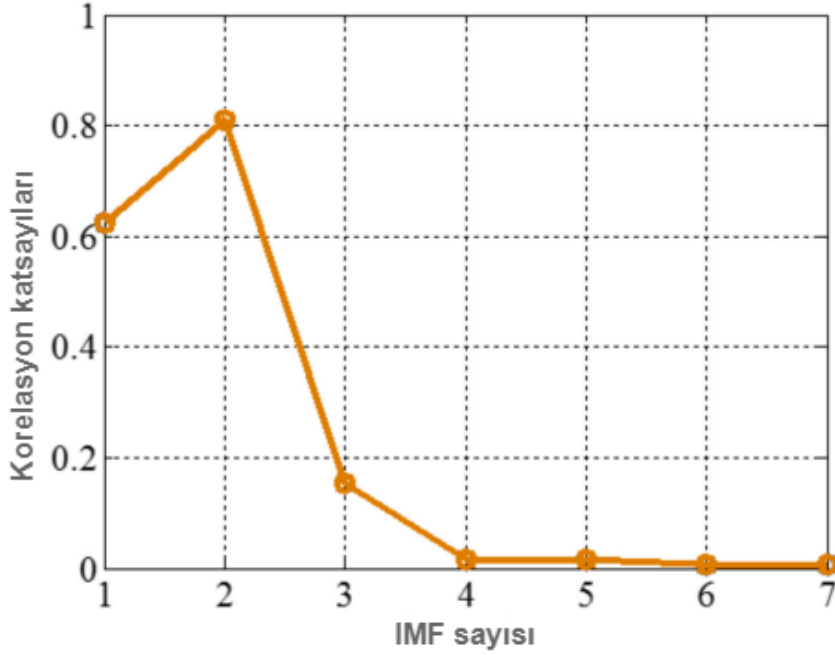
---

**Algorithm 1: CEEMDAN** sinyal ayrıştırma metodu

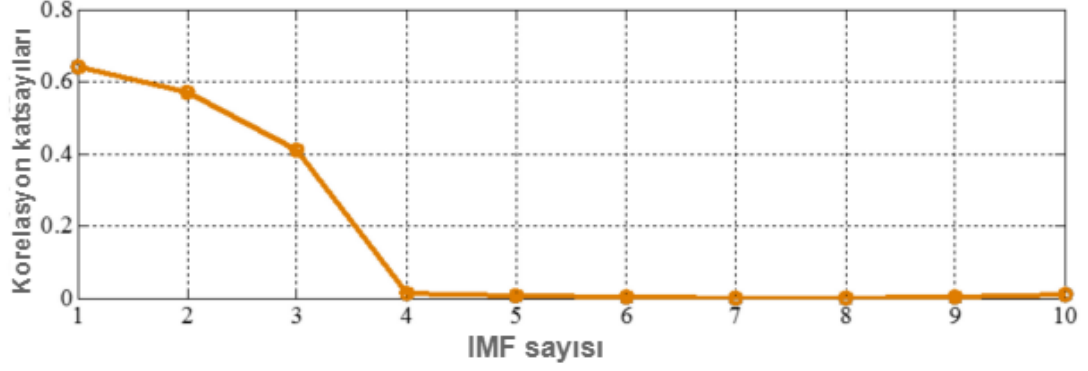
---

```
decompose()  
  Result: Ayrıştırılmış modlar ( $IM\tilde{F}_K$ )  
1   $r_k(n) \leftarrow$  Artıklar  
2   $E_j(\cdot) \leftarrow$   
   bir sinyal verildiğinde EMD kullanılarak elde edilen j'inci modunu üretir  
3   $w^i \leftarrow$  Beyaz gürültü  
4   $x(n) \leftarrow$  hedeflenen veri  
5   $I \leftarrow$  gerçekleştirme sayısı  
6   $IMF_1^i(n) = x(n) + \epsilon_0 w^i(n)$   
7   $IM\tilde{F}_1(n) = 0$   
8  for  $i=1$  to  $I$  do  
9  |  $IM\tilde{F}_1(n) = IM\tilde{F}_1(n) + IMF_1^i(n)/I \leftarrow$  birinci mod  
10 end  
11  $r_1(n) = x(n) + IM\tilde{F}_1(n) \leftarrow$  birinci artık  
12  $IM\tilde{F}_2(n) = 0$   
13 for  $i=1$  to  $I$  do  
14 |  $IM\tilde{F}_2(n) = IM\tilde{F}_2(n) + E_1(r_1(n) + \epsilon_1 E_1(w^i(n))) / I \leftarrow$  ikinci mod  
15 end  
16 while  $r_k(n) \leftarrow$  en az iki extraması olana kadar do  
17 | for  $k=2$  to  $K$  do  
18 | |  $r_k(n) = r_{k-1}(n) - IM\tilde{F}_k(n) \leftarrow k=2, \dots, K$  için artıklar  
19 | |  $IM\tilde{F}_k(n) = 0$   
20 | | for  $i=1$  to  $I$  do  
21 | | |  $IM\tilde{F}_{k+1}(n) = IM\tilde{F}_{k+1}(n) + E_1(r_k(n) + \epsilon_k E_k(w^i(n))) / I$   
22 | | end  
23 | end  
24 end
```

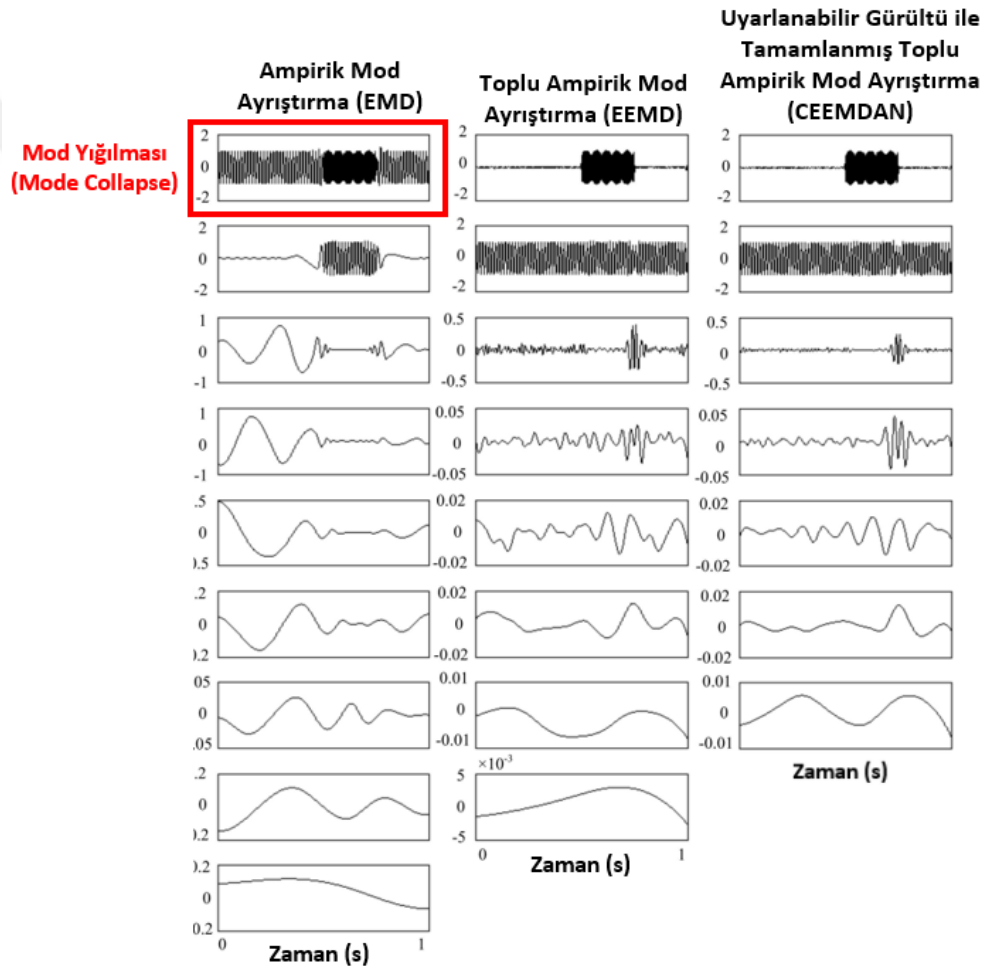
---



Şekil 2.17: Farklı IMF'lerin korelasyon katsayıları (EMD).



Şekil 2.18: Farklı IMF'lerin korelasyon katsayıları (EEMD).



Şekil 2.19: EMD, EEMD ve CEEMDAN karşılaştırması.

## 2.8 Tırlama Tespitinde Sinyal Ayrıştırma ve AI

Yıllar boyunca, tırlama algılama ve AI ile tanımlama alanı, öne çıkan bir araştırma alanı olmuştur. AI, başlıca ML ve DL algoritmalarının paternleri tanımlama ve

karmaşık ve doğrusal olmayan sorunları çözme yetenekleri nedeniyle, çeşitli gerçek yaşam uygulamalarında yaygın olarak kullanılmaktadır. Belirli yaklaşımlar arasında, farklı verilerle ve karmaşıklıkla başa çıkma kapasitelerine dayalı olarak belirli bir ilişki vardır. Tırlama durumlarını gösterebilecek özelliklerin belirlenmesi ve tanımlanması, veri toplama, sinyal işleme, özellik seçimi ve özellik çıkarma, ML kullanılırken tırlama algılama sürecindeki tüm işlemlerdir. DL yaklaşımları öznelik çıkarımını kendi içinde yaptığından, uzun süren ve zahmetli öznelik seçimi ve çıkarımı aşamalarından geçmek zorunda kalmadan oldukça doğrusal olmayan örneklerle başa çıkabilmektedirler. Son zamanlarda, birçok DL yöntemi, tırlama tespiti için uyarlanmıştır. Şener vd. temel tırlama açısından zengin verileri ortaya çıkarmak için bir ön işleme yaklaşımı olarak CWT kullanmıştır [58]. Bunu takiben, oluşturulan derin CNN'yi eğitmek ve değerlendirmek için CWT görüntüleri kullanılmıştır. Kesme parametreleri CNN ağına girdi olarak sağlandığında, tekniğin doğrulanması Şener vd.'ye göre ortalama doğruluğa ulaşmıştır.

Tırlama tespiti için sadece işlenmiş parça yüzeyleri veya CWT çıktıları gibi 2 boyutlu görüntüler değil, aynı zamanda bir ivmeölçer ile toplanan orijinal sinyaller veya ön işleme sonrasında elde edilen 1 boyutlu sinyaller de kullanılmaktadır [79]. Ancak, DL algoritmalarının işlevlerini yerine getirebilmesi ve iyi doğruluk değerleri elde edebilmesi için yukarıda verilen örneklerde olduğu gibi büyük miktarda veriye ihtiyaç vardır.

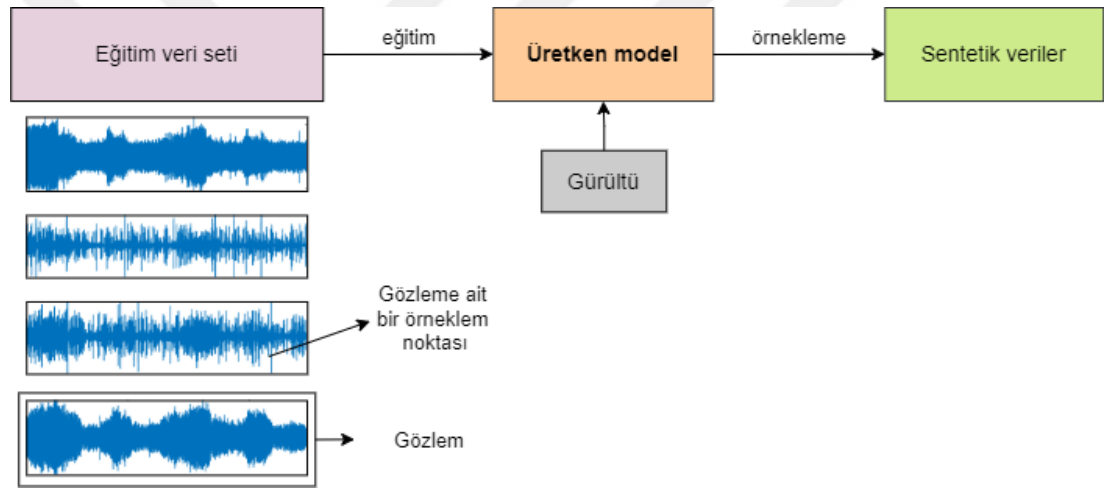
## 2.9 Veri Dağılımı Eşitsizliği

Bir DL algoritmasının ayarlanması gereken çok sayıda parametre nedeniyle, sınıfsal olarak dengeli ve büyük miktarda veriye ihtiyaç duymaktadır. Dengeli bir veri kümesi, her bir durumdan benzer sayıda örnek içeren bir veri kümesidir. Ancak gerçek dünyada, çeşitli makine ve takım durumları altında elde edilen arıza verileri dengesizdir. Çalışma aşamasında, CNC makinelerinin arızalanma olasılığı düşüktür ve farklı koşullar altında kararlı durumda büyük miktarda işleme kesme verisi toplamak kolaydır, oysa işleme hata verileri sınırlıdır. Sonuç olarak, modelleri başarısızlık durumu hakkında eğitmek için nispeten az veri bulunabilmektedir [64,65,66]. Karmaşık çalışma koşullarının arıza özellikleri üzerindeki önemli etkisinden dolayı, dengesiz veri seti, sınıflandırma modelinin tırlama algılama

performansını etkiler. DL tabanlı üretken modeller kullanılarak, sınırlı sayıda tırlama örneği artırılabilir ve böylece sınıflandırma doğruluğu iyileştirilebilir [67].

## 2.10 Üretken Modeller

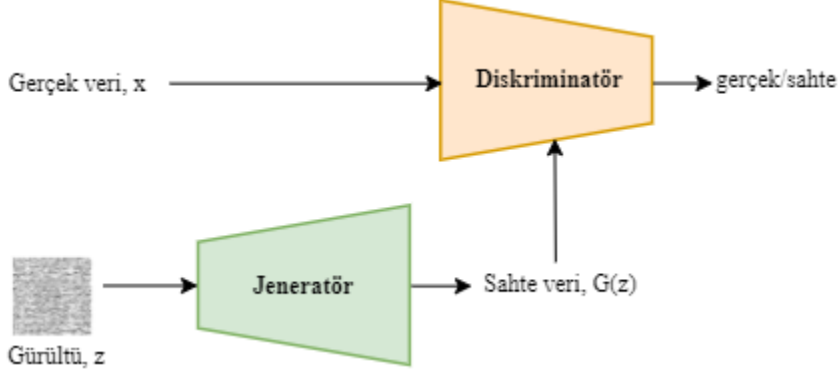
DL alanında, ayırt edici modeller kullanarak bir hedefi doğrudan öğrenmenin zor olduğu birçok örnek vardır ve bu durumlarda, hedef ve eğitim verilerinin ortak dağılımı tahmin edilir ve sentetik veriler oluşturulur [68]. Otopregresif modeller gibi birçok üretken model olmasına rağmen, NF'ler ve VAE'ler, GAN'lar en çok sıklıkla kullanılan modellerdir [69,70,71]. Sentetik veri üretmedeki başarısı nedeniyle GAN'lar, diğer üretici modellere göre popülerlik kazanmıştır. 1 boyutlu girdi alan üretici modellerin genel çalışma şeması Şekil 2.20'de gösterilmiştir.



Şekil 2.20: Üretici ağlardaki için veri sentezleme sistemi.

### 2.10.1 Üretken çekişmeli ağ (GAN)

GAN'lar, denetimsiz bir şekilde oluşturulan verilerin kalitesini artırmak için çekişmeli süreçleri kullanma teorisine dayanır [71]. Bu çekişmeli süreçte, iki ağ aynı anda eğitilir. Bunlar üretici olan jeneratör  $G$  ve ayırmacı olan diskriminatör  $D$ 'dir. Jeneratör, girdi olarak rastgele gürültü  $z$  kullanır ve veri sentezini yaparken çıktı olarak sentetik veri  $G(z)$  üretir. Diskriminatör ise, girdi olarak  $x$  gerçek veriyi ve  $G(z)$  sentetik veriyi (jeneratör tarafından üretilmiş) alır ve  $x$  için  $D(x)$  ve  $G(z)$  için  $D(G(z))$  çıktısını verir. Oluşturucu gerçek gibi görünen sentetik veriler üretirken, ayırmacı ağ sahte ve gerçek verileri ayırt etmeye çalışır. GAN yapısı Şekil 2.21'de gösterilmektedir.



**Şekil 2.21:** GAN yapısı.

Ayırt edici ağ eğitiminin amacı, doğru etiketi hem gerçek hem de üretici ağdan gelen sentetik örneklere tahsis etme olasılığını en üst düzeye çıkarmaktır. GAN'ların min-maks kayıp olarak bilinen yitim fonksiyonu aşağıdaki gibi ifade edilir;

$$E_{x \sim P_{\text{data}}(x)} [\log D(x)] + E_{z \sim P_Z(z)} [\log (1 - D(G(z)))] \quad (2.20)$$

burada  $E_{x \sim P_{\text{data}}(x)}$  ve  $E_{z \sim P_Z(z)}$  sırasıyla ayırıcının gerçek örnek dağılımı hakkında yapması beklenen tahmin ve gürültü vektörüdür. Aşağıdaki kayıp fonksiyonunu maksimize ederek, ayırıcı ağ yanlış sınıflandırma için kendini cezalandırır.

$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m [\log D(z^{(i)}) + \log (1 - D(G(z)))] \quad (2.21)$$

Benzer bir durum üretici ağ için de geçerlidir. Ayırıcı ağı kandırabildiğinde ödüllendirilir, aksi takdirde cezalandırılır. Amaç aşağıdaki fonksiyonu minimize etmektir.

$$\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m \log (1 - D(G(z))) \quad (2.22)$$

İdeal GAN eğitimi sırasında, üretici ağ ve ayırıcı ağ Nash dengesine ulaşana kadar sıfır toplamlı oyun oynamaya devam eder. İdeal noktaya ulaşmak her zaman kolay olmayabilir. Sentetik veri üretmede kullanılan ağların başında gelen GAN, eğitimleri aşamasında bazı sorunlarla karşılaşılabilir. Bu dezavantajlar, örneğin, kaybolan gradyanlar, mod çökmesi ve performans eksikliğidir.

Kaybolan gradyanların nedeni, eğitimin başında oluşan üretici ağı ayırıcı ağı karşı zayıf olmasıdır. Sonuç olarak, kolayca ayırt edilebilen örnekler üretilir ve veriler, diskriminatör tarafından kolayca ayırt edilebilir. Bu duruma bir çözüm olarak, orijinal GAN makalesinde doygun olmayan üreteç yitimi önerilmektedir [71]. Bu, üretici ağı  $\log(1-D(G(z)))$  değerini en aza indirmek yerine  $\log(D(G(z)))$  değerini en üst düzeye çıkarması ilkesine dayanır. Bu şekilde doygunluk sorunu çözülebilir. Bu nedenle, ayırıcı ağı eğitimin erken aşamalarında daha güçlü gradyanlar sağlayabilir.

GAN'ın kullanıldığı birçok durumda, çıktılarda çeşitlilik olması arzu edilir. Bununla birlikte, jeneratör özellikle ikna edici bir sonuç sağlıyorsa, jeneratör sadece o örneği öğrenebilir. Gerçekte, jeneratör sürekli olarak diskriminatörün en olası olduğu konusunda hemfikir olduğu çıktıyı üretmeye çalışır. Diskriminatörün en iyi tekniği, jeneratör aynı ürünü tekrar tekrar üretmeye başlarsa, oluşturulan sınırlı bir dizi numuneyi her zaman iptal etmeyi öğrenmektir. Mod çökmesi, bu tür GAN hatası için kullanılan terimdir. Mod çökmesi ile başa çıkmak için bazı yaklaşımlar geliştirilmiştir. Wasserstein yitimi, açılmamış GAN metodu ve daha geniş bir özellik yelpazesi oluşturmasını sağlamak için jeneratörün nöron sayısını arttırmak bazı örneklerdir [72,73].

GAN eğitimini zorlaştıran bir diğer faktör ise yakınsamanın uzun zaman alabileceği gerçeğidir. Eğitim performansını iyileştirmek, sentetik verileri koşullandırmak ve çok modlu bir model öğretmek için koşullu üretken çekişmeli ağlar (CGAN) tanıtılmıştır.

### **2.10.2 Koşullu üretken çekişmeli ağ (CGAN)**

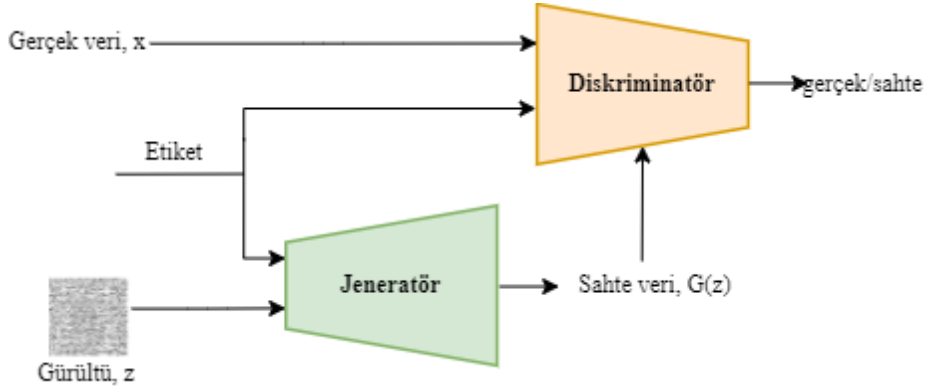
GAN'lar aynı anda eğitilmiş iki ağdan oluşur. Bunlar üretici ve ayırıcıdır. Her iki ağ da ek bilgilerle koşullandırıldığında, üretici hasım ağları bir CGAN'a genişletilebilir [74]. Bu tür etiketler veya farklı modalitelerden gelen veriler dahil olmak üzere her türlü yardımcı bilgi, ekstra bilgi olarak adlandırılabilir. Koşulsuz modellerde üretilen sentetik veri modlarında herhangi bir kontrol yoktur.

GAN'lar, hem oluşturucu hem de ayırıcı, etiketler gibi y bazı ek bilgilere koşullandırıldığında, koşullu bir derin öğrenme modeline genişletilebilir [74]. Koşullandırma, y'yi diskriminatöre ve jeneratöre ekstra bir girdi katmanı olarak koyarak yapılabilir. CGAN'lara etiket bilgisi gürültü ile birlikte jeneratöre girdi

olarak verilir. Benzer şekilde, ayırım işlemi yapılırken girdi örneğine ek olarak ayırmacıya etiketler verilir. Standart GAN maliyet işlevine oldukça benzer, CGAN maliyet işlevi şu şekilde ifade edilir;

$$E_{x \sim P_{\text{data}}(x)}[\log D(x | y)] + E_{z \sim P_z(z)}[\log (1 - D(G(z | y)))] \quad (2.23)$$

CGAN yapısı Şekil 2.22'de gösterilmektedir.



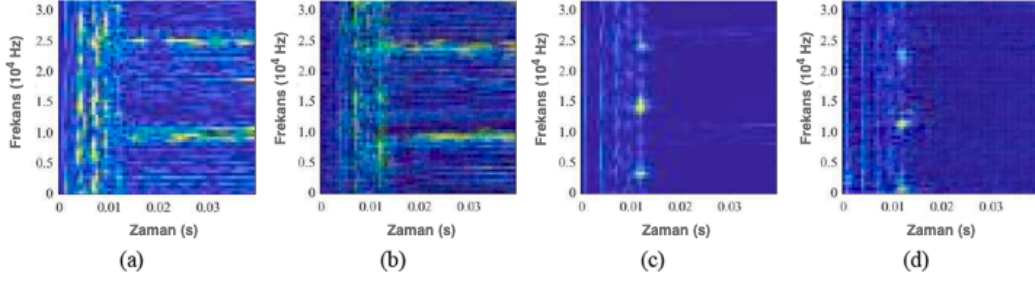
Şekil 2.22: CGAN yapısı.

## 2.11 Makinelerde Hata Tespiti

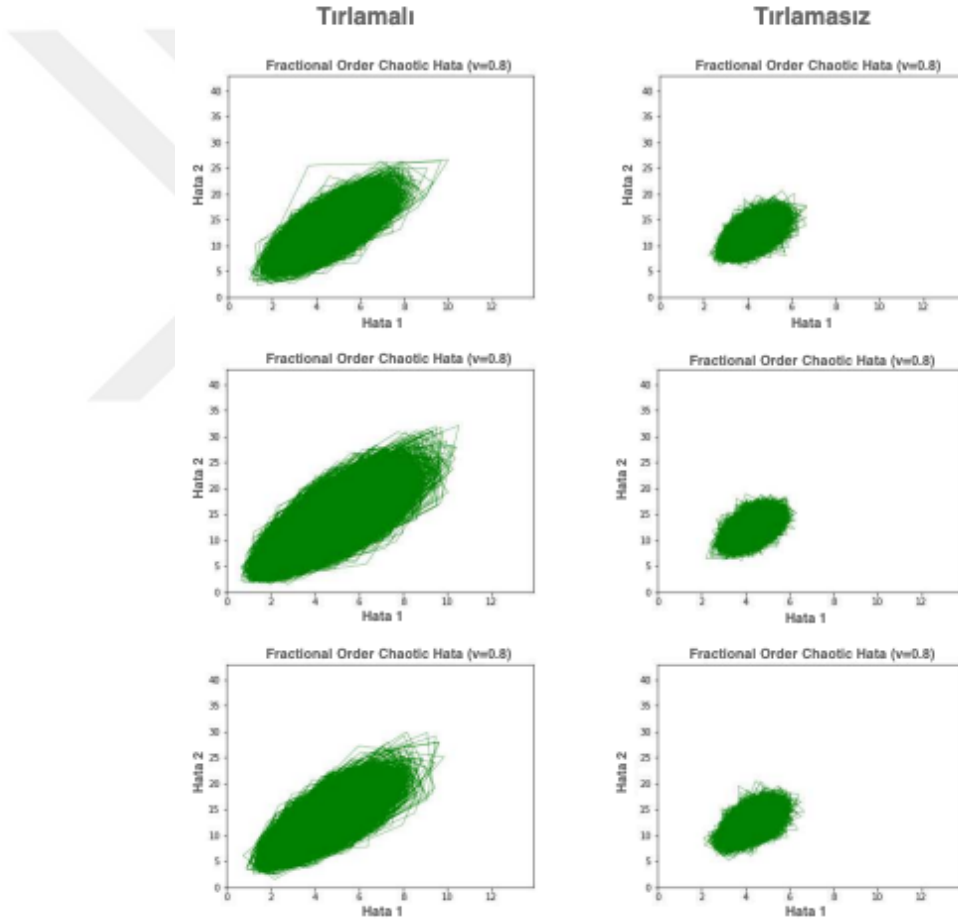
Standart ve çeşitli modifiyelerden geçmiş GAN türlerinin veri dağılımı eşitliği olmayan arıza/hata teşhis yöntemlerinde kullanımı oldukça yaygındır. Veri dengesizliği sorunuyla başa çıkmak için farklı yöntemler önerilmektedir. Örneğin, Liu vd. Hata verilerinin dağılımını dengeleyecek sahte (sentetik) zaman-frekans alanı özellikleri üretmek için çok ölçekli artık GAN adı verilen yeni bir yaklaşım önermişlerdir [75]. Bu çalışmada girdi olarak frekans dilimi dalgacık dönüşümü görüntülerini kullanmışlardır. Bu yayında bahsi geçen gerçek ve sentetik veriler Şekil 2.23'te gösterilmiştir.

Kuo vd. iki boyutlu hata haritalarını girdi olarak alan bir yöntem önermiştir [76]. Bu hata haritaları, sinyallerin Chen-Lee kaotik sistemi ile ön işlenmesiyle elde edilmiştir. Bahsedilen hata haritalarına ait örnekler Şekil 2.24'te verilmiştir. Bu yöntemle elde edilmesi oldukça güç olan tırlama sinyallerinin oluşturduğu dengesiz veri kümesi problemine sentetik hata haritaları üretecek bir çözüm önermişlerdir.





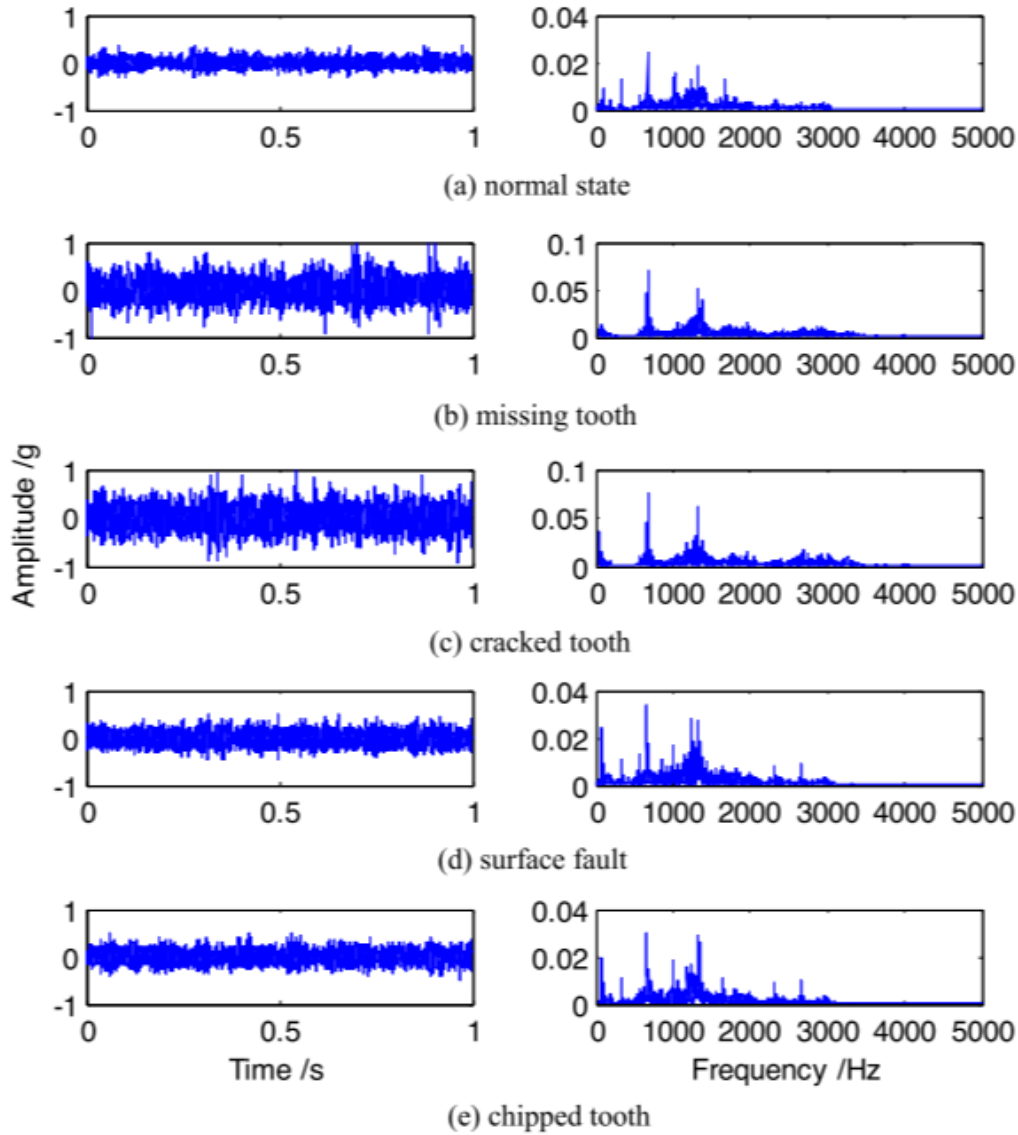
**Şekil 2.23:** İki arıza durumunun orijinal ve üretilen TF görüntüleri: (a) IRF durumunun orijinal görüntüsü; (b) IRF durumunun sentezlenmiş görüntüsü; (c) ORF durumunun orijinal görüntüsü; (d) ORF durumunun sentezlenmiş görüntüsü [75].



**Şekil 2.24:** Tırlamalı ve kararlı örneklere ait hata haritaları [76].

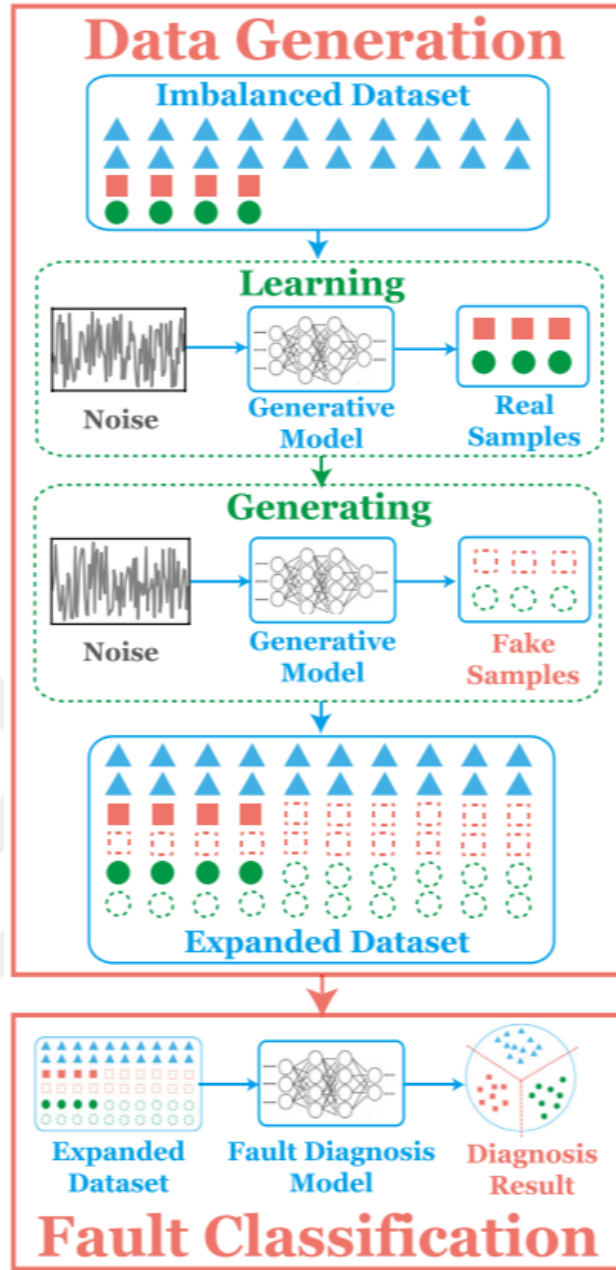
Çeşitli GAN'lara girdi olarak bahsedilen iki boyutlu görüntüleri kullanan çalışmaların yanı sıra, girdi olarak bir boyutlu titreşim sinyallerini kullanan bazı çalışmalar da vardır. Örneğin, hataları teşhis etme potansiyelini arttırmak için, Liu vd. VAE ile GAN'ı birleştiren bir veri büyütme tekniği önermişlerdir [67]. Wang vd.

GAN ve yığılmış gürültü giderici AE kullanılarak tanınan planet dişli kutusu arıza kalıpları ve küçük miktarlarda örnek için iyileştirilmiş arıza algılama performansı elde etmişlerdir [77]. Eğitim için farklı rulman arıza tiplerine ait sinyaller kullanmışlardır. Veri setlerine ait örnekler Şekil 2.25'te gösterilmiştir.



**Şekil 2.25:** Orijinal titreşim sinyallerinin zaman alanı ve frekans alanı örnekleri [77].

Kategorik çekişmeli AE, Liu vd. tarafından etiketleri olmadan rulman arızalarını teşhis etmek için kullanmıştır [78]. Zhang vd. dengesizlik veri kümesi sorununu çözmek için her bir arıza sınıfı için ayrı GAN'lar eğiterek DL tabanlı bir döner makinelerde arıza teşhis yöntemi kullanmıştır [79]. Bahsedilen metoda ait yöntem şeması Şekil 2.26'da gösterilmiştir.



**Şekil 2.26:** Önerilen metoda ait akış şeması [79].

Üretken modellere girdi olarak iki boyutlu görüntüler vermek yerine bir boyutlu sinyaller vermek, eğitim sürelerinde önemli azalmalar elde edilmesini sağlayabilmektedir. Ayrıca orijinal sinyalin girdi olarak kullanılması, üretilen çıktı sinyallerine birçok farklı sinyal işleme yönteminin uygulanmasına, yani çıkışın 1 boyutlu formda olması nedeniyle sentetik verilerle çok özgür bir çalışma ortamına izin verir. Hatta sentetik veriler üretilip veri kümesi dengelendikten sonra iki boyutlu görüntülerin sınıflandırılmasında kullanılan derin CNN mimarileri yerine çok daha hızlı çalışabilen SVM gibi ML yöntemlerinin kullanılmasına da olanak tanır.



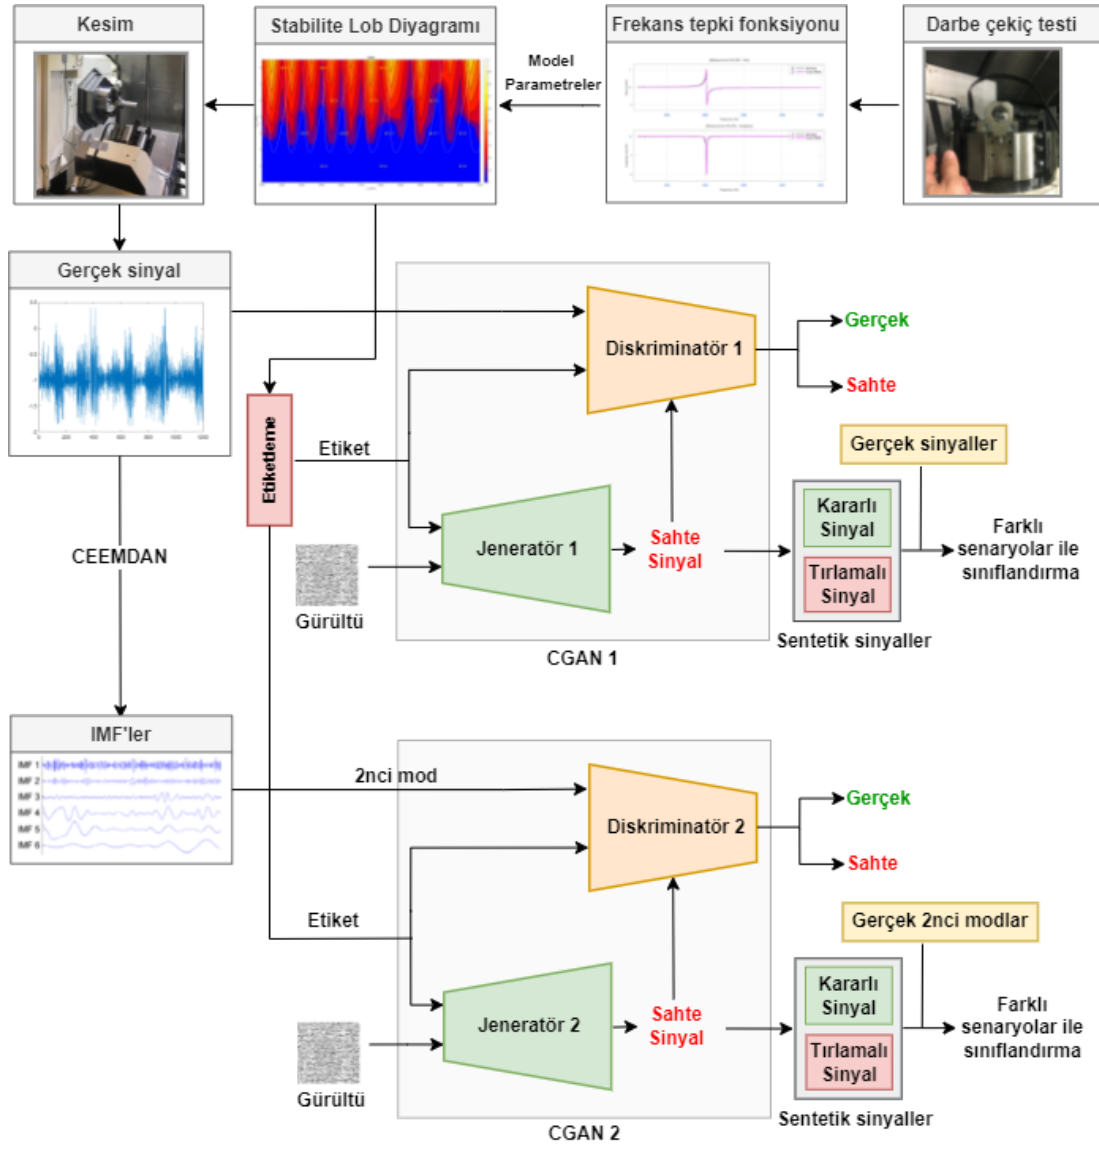
### 3. DENEYSEL YÖNTEM

Bu tez kapsamında, tornalama operasyonlarında dengesiz tırlama algılama performansını iyileştirmek için sentetik sinyaller üretmek amaçlanmaktadır. Tüm sistem üç ana bölümden oluşmaktadır. Bunlar, sinyal toplama ve sinyal işleme, sentetik sinyal üretimi ve senaryo tabanlı tırlama tespitidir. Öncelikle, sistemin dinamik özellikleri bir darbe testi tapılarak incelenmiştir. SLD'nin geliştirilmesi için modal parametreler elde edilmiştir. Daha sonra tornalama deneyleri yapılmıştır. Veriler toplanmıştır ve CEEMDAN ile ayrışma için önceden bir takım sinyal işleme metotları uygulanmıştır. Sinyal etiketleri öncelikle SLD'ye göre seçilmiştir. Bununla birlikte, sinyal etiketlerini daha güvenilir ve net bir şekilde tanımlamak için IMF'ler üzerinde de çalışılmıştır. Her sinyal ayrı ayrı analiz edildikten sonra her biri etiketlenmiştir. CGAN modelleri daha sonra etiketli zaman alanı sinyalleri ve CEEMDAN ayrıştırmasından elde edilen ikinci modlar kullanılarak eğitilmiştir. Son olarak, inşa edilen modelin performansını değerlendirmek için test için ayrılan örnekler kullanılmıştır. Şekil 3.1 veri oluşturma ve sınıflandırma sürecinin tüm akışını göstermektedir.

#### 3.1 Takım Tezgâhı ve Deneysel Kurulum

Bu tez kapsamında yapılan deneylerde yatay işleme merkezi olan MAZAK Integrex i-200ST kullanılmıştır. Bahsi geçen tezgâh TOBB ETÜ Teknoloji Merkezi'nde bulunmaktadır. Bu tezgâha ait fotoğraf Şekil 3.2'de gösterilmiştir.

Tornalama işlemleri için katerli bir Walter elmas şekilli karbür torna ucu seçilmiştir. Tornalama işlemlerinde alüminyum 7075 iş parçaları kullanılmıştır. Çizelge 3.1, takım, iş parçası ve kesim parametrelerini listelemektedir.



Şekil 3.1: Tez kapsamında izlenen yöntemi özetleyen akış şeması.



Şekil 3.2: MAZAK Integrex i-200ST yatay işleme merkezi.

**Çizelge 3.1:** Kesici takım, kesim ve iş parçası parametreleri.

<b>Kesici Takım</b>	
Şekil	Elmas
Açı (derece)	55
Kaplama	TiAlN
Köşe yarıçapı (mm)	0,79
Talaş açısı	Negatif
Kesim yönü	Nötral

<b>Kesim Parametreleri</b>	
Operasyon	Tornalama
Kesme derinliği aralığı- çap (mm)	2-10
Besleme (mm)	0,08
Kesim hızı aralığı	2000-4200


<b>İş Parçası</b>	
Malzeme	Al 7075
Boyutlar (mm)	Çap=50 Uzunluk=160

**Çizelge 3.2:** MAZAK Integrex i-200ST yatay işleme merkezi özellikleri.

<b>Kapasite</b>	
Maksimum İşleme çapı	658 mm
Maksimum İşleme Uzunluğu	1519 mm
Çene Boyutu	8 in
İş Mili Maksimum Hızı	5000 rpm
Maksimum İş mili Gücü	30 hp

Titreşim verileri, 101 mV/g hassasiyete sahip üç eksenli bir ivmeölçer kullanılarak toplanmıştır. İvmeölçer marka ve modeli PCB Piezotronics 356A15'tir. Modal parametreler, 1,1 mV/N hassasiyetli PCB Piezotronics 086C04 isimli hassas darbeli çekici kullanılarak elde edilmiştir. Cihazlar bir National Instruments 9234 Veri

Toplama (DAQ) modülü ile eşleştirilmiştir. DAQ sistemi maksimum 51200 Hz'lik bir örnelemeye sahiptir. Veri toplama için LabVIEW™ yazılımı kullanılmıştır. İvmeölçer deneyler sırasında katere yapıştırılmıştır. Tornalama deneyleri ve darbe testleri 51200 Hz örnekleme hızında yürütülmüştür. Kullanılan ekipman ve deneysel kurulum Şekil 3.3'de gösterilmiştir.

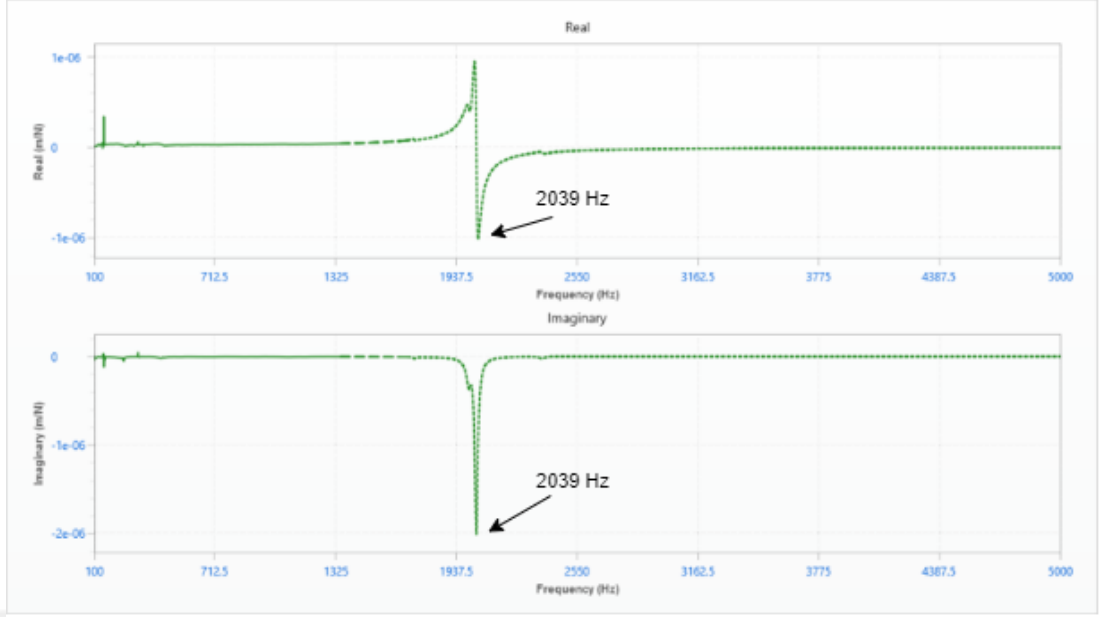


Şekil 3.3: Deneysel kurulum ve test ekipmanları.

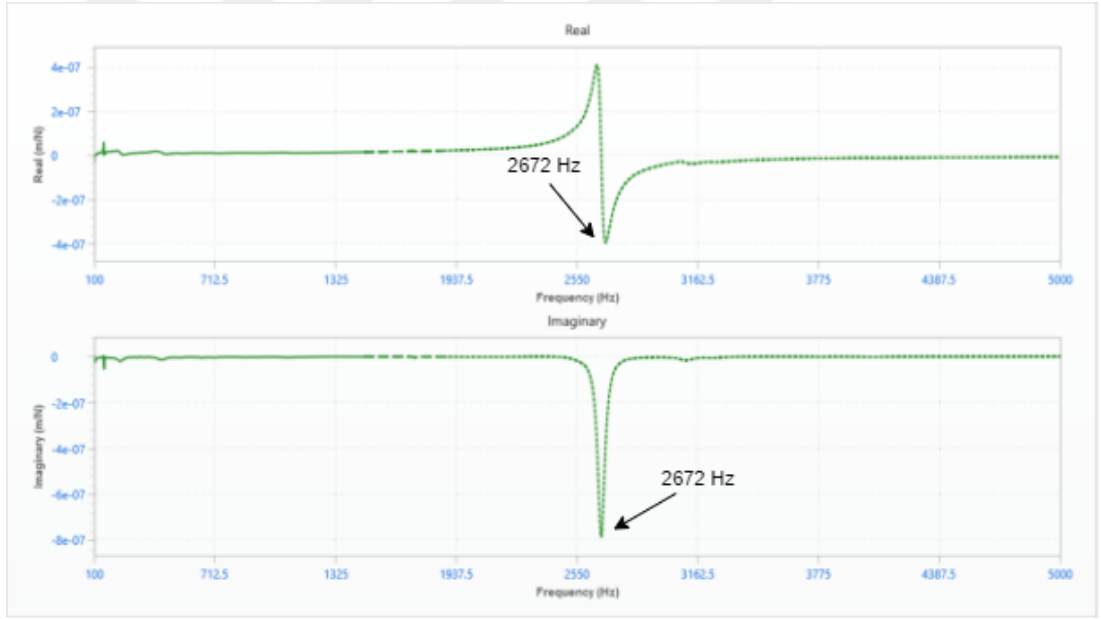
### 3.2 Sisteme Ait Dinamik Özelliklerin Elde Edilmesi

Sistemin SLD'sini ortaya çıkarmak için sistemin dinamik karakteristiklerini bilmek gerekmektedir. Modal analizler, deney düzeneği ile aynı DAQ ekipmanı kullanılarak ve 5000 Hz frekans aralığı darbe çekici ile gerçekleştirilmiştir. CutPRO™ yazılımı, modal frekansları ve FRF diyagramlarını elde etmek için kullanılmıştır. Mod frekansları, bitişik takım konumu ve aralıklı takım konumu için sırasıyla 2672 Hz. ve 2039 Hz'dir. FRF'ler sisteminin gerçek ve sanal kısımları, bitişik takım konumu için Şekil 3.4'te ve aralıklı takım konumu için Şekil 3.5'te verilmiştir.





**Şekil 3.4:** Bitişik takım konumuna ait FRF.

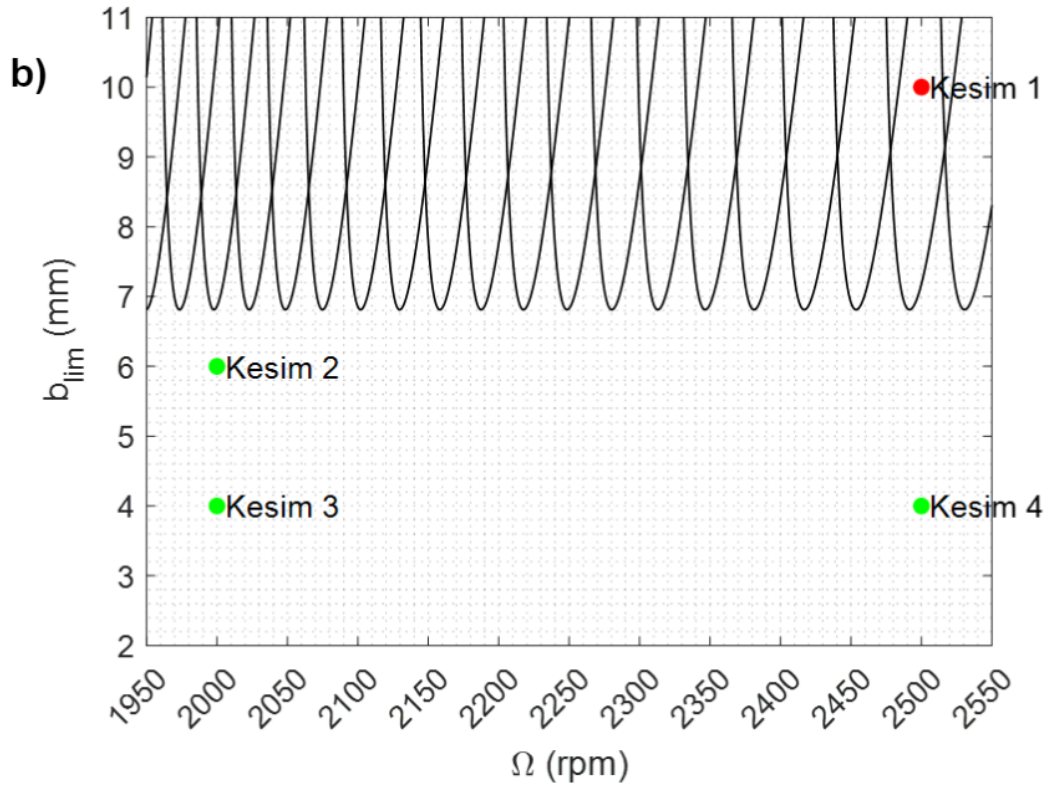



**Şekil 3.5:** Ayrık takım konumuna ait FRF.

Şekil 3.6'daki SLD'ler, sayısal yönteme odaklanan tornalama prosesinin zaman alanlı bir simülasyonu kullanılarak oluşturulmuştur. SLD'ye bakılarak toplamda sekiz kesim (2000-3600 RPM aralığı ile 2-10 kesme derinliği arasında) gerçekleştirilmiştir. Kesimler dört adet ayrık takım pozisyonunda ve dört adet de bitişik takım konumunda yapılmıştır. Yapılan tüm kesim deneylerine ait parametrelere ve ilgili etiketlere Çizelge 3.3'te yer verilmiştir.

**Çizelge 3.3:** Yapılan tüm kesimlere ait parametreler.

<b>Kesim Numarası</b>	<b>Takım Pozisyonu</b>	<b>İş Mili Hızı (RPM)</b>	<b>Kesme Derinliği (mm)</b>	<b>Etiket</b>
1	Bitişik	2500	10	Tırlama
2	Bitişik	2500	4	Kararlı
3	Bitişik	2000	4	Kararlı
4	Bitişik	2000	6	Kararlı
5	Ayrık	3500	8	Tırlama
6	Ayrık	3600	4	Kararlı
7	Ayrık	3500	2	Kararlı
8	Ayrık	3400	4	Kararlı

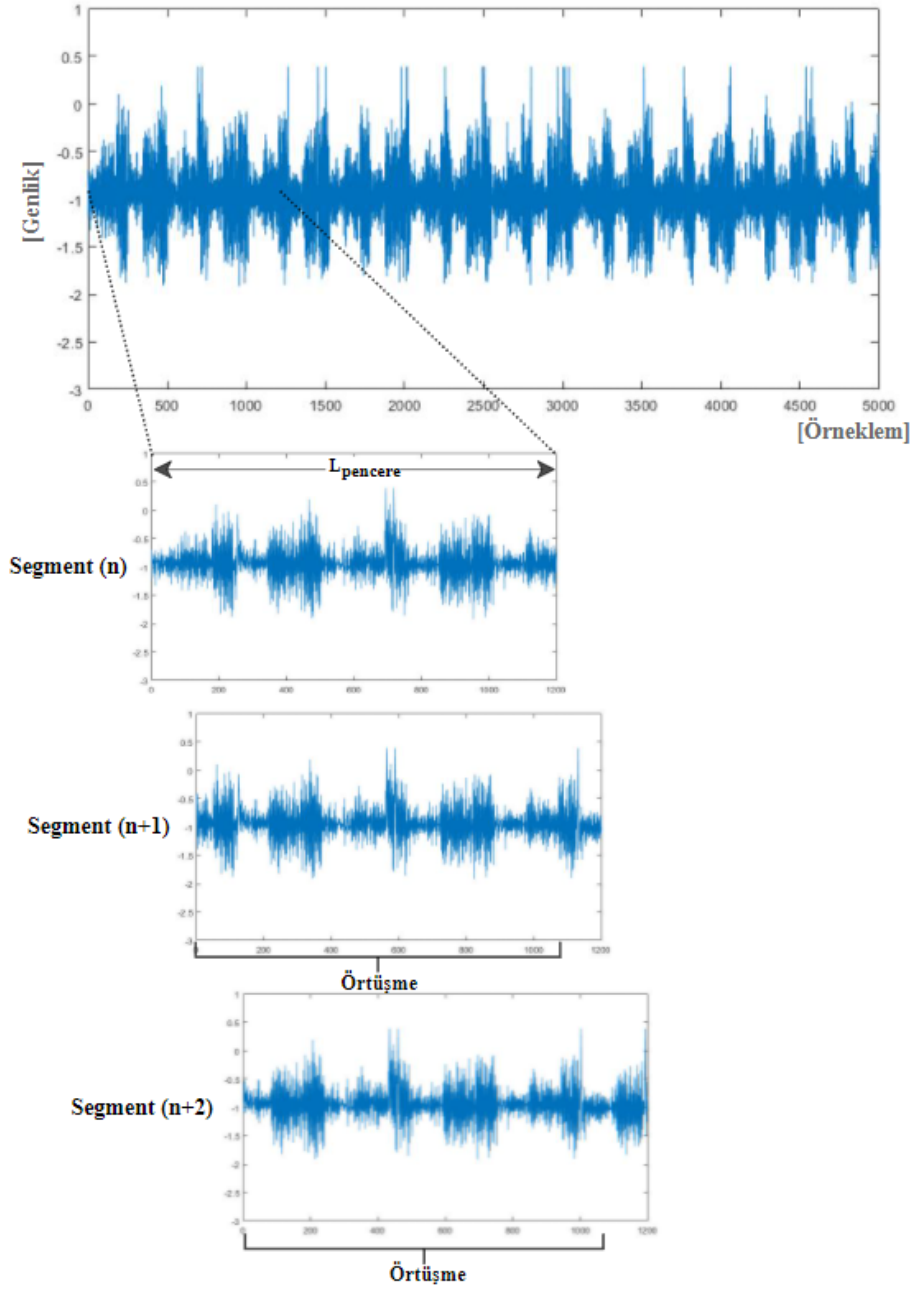


**Şekil 3.6:** İki farklı takım konumuna ait SLD'ler a) Ayrık takım konumu b) Bitişik takım konumu

### 3.3 Sinyal Önışleme

Sinyaller toplanırken iyi yalıtılmıř bir ortamda olmadığında, operatörün neden olduđu deęiřen kesme bařlangıç ve bitiř zamanları olduđu ve talař kaldırma gibi yüksek titreřimli iřlemler yapıldığında sinyallerde aykırı deęerler ve istenmeyen kısımlar ortaya çıkar. Bu tür durumlarla karřılařıldığında, iyi bir veri seti oluřturmak ve bunları DL algoritmaları için girdi olarak kullanılabilir hale getirmek için sinyallerin bazı ön iřleme süreçlerinden geçmesi gerekir. Bu nedenlerle, sinyaller toplandıktan sonra sinyallerin bařındaki ve sonundaki kesilmemiř kısımlar atılmıřtır. Ek olarak, sinyal ile iç içe geçmiř istenmeyen gürültü kaynaklı ani yükselmeleri gidermek için gürültü giderme filtreleri uygulanmıřtır. Son olarak, sinyalleri GAN'a girdi olarak vermek için, sinyaller kayan pencere algoritması çoęaltılmıřtır.

Tanımlı uzunluktaki bir pencere  $L_{pencere}$ , bu algoritmada sinyal örneğinde üzerinde kaydırılır. Bu teknik, DL algoritmalarını eęitmek için yeterli veri olmadığında kullanılan veri büyütme yöntemlerinden biridir. Bu algoritmaya girdi olarak sinyalin karakteristik özelliklerini kaybetmemek için belirtilen pencere uzunluđu ve pencere kaydırma mesafesi parametrelerini girdi olarak verilir. Çıktı olarak,  $L_{pencere}$  kaymasına (segment  $n$ ,  $n+1$ ,  $n+2...$ ) eřit ortak (örtüřen) parçalara sahip sinyaller üretilir. Őekil 3.7'de kayar pencere ve sinyal segmentleri gösterilmiřtir.



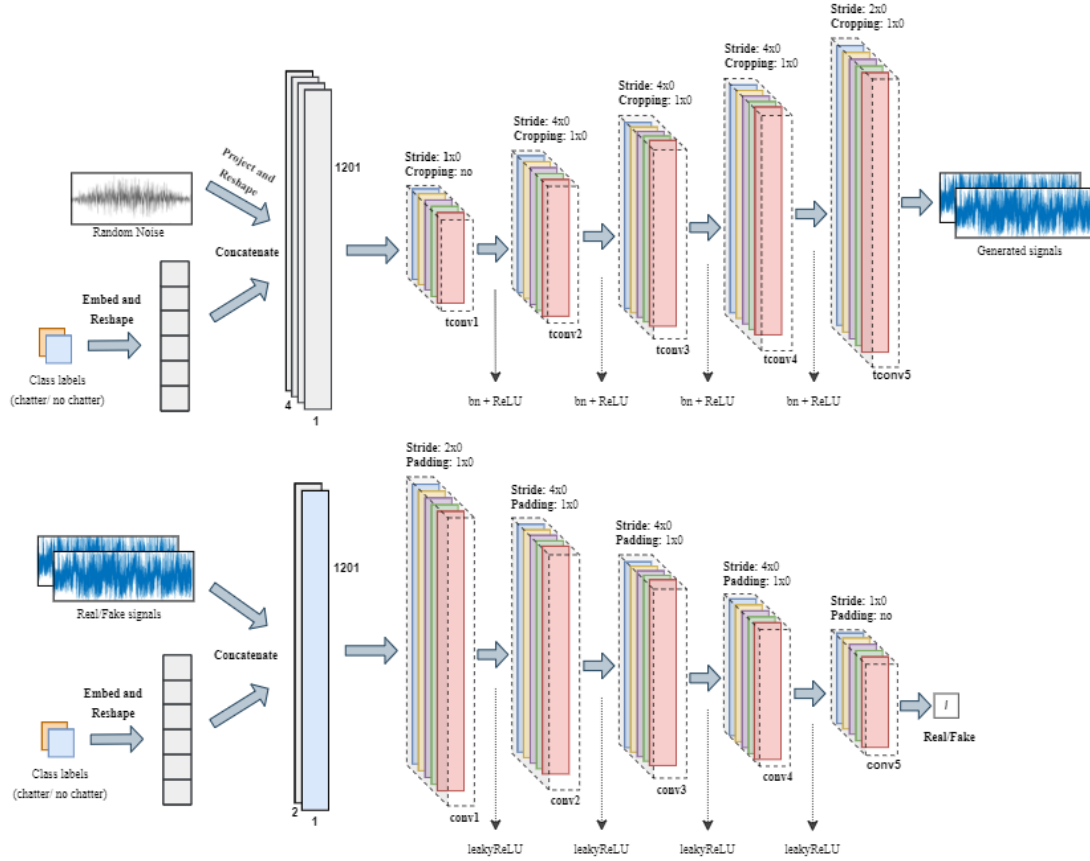
Şekil 3.7: Kayar pencere uygulaması.

### 3.4 CGAN Tasarımı

Bu bölümde tez kapsamında kullanılmış CGAN yapısına ait detaylar verilecektir. Sentetik veri üretilirken CGAN'lara girdi olarak;

- 1) ham zaman alanı sinyalleri
- 2) CEEMDAN'dan geçirilmiş zaman alanı sinyalleri
- 3) "tırlama" ve "kararlı" olmak üzere iki farklı türde etiket bilgisi

verilmiştir. Modele, grup (batch) boyutu 256 olacak şekilde bir sinyal girdisi sağlanmıştır. Oluşturulmuş CGAN mimarisi iki ağdan oluşur. Bunlardan ilki, diskriminatörü kandırmak için sentetik verileri sentezleyen jeneratör ağıdır. Diğeri ise jeneratör tarafından üretilen sentetik verilerden gerçek verileri ayırmaya çalışan diskriminatör ağıdır. Şekil 3.8, oluşturulan CGAN modelinin tüm katmanlarını, dolgu (padding) ve kırpma (cropping) boyutları dahil göstermektedir.



**Şekil 3.8:** Tez kapsamında kullanılmış CGAN mimarisi.

Jeneratör ağında sınıf etiketleri, gömme ve yeniden boyutlandırma katmanından geçirilir. Rasgele gürültü de yansıtma ve yeniden boyutlandırma katmanından geçirilir. Bu iki katmanın çıktıları bir birleştirme katmanı ile birleştirilir. Kalan kısımda, sırasıyla dört katman kümesi ve çıkış kısmında bir tconv (transposed convolution- devrik konvolüsyon) katmanı vardır. Bu kümeler tconv katmanı, bn(batch normalization- grup normalizasyon) katmanı ve ReLU aktivasyon fonksiyonu katmanından oluşur. ReLU aktivasyon fonksiyonu formülü Denklem 3.1’de gösterilmiştir ve doğrusal olmamayı sağlamak için kullanılmıştır.

$$y = \max(0, x) \quad (3.1)$$

tconv1, tconv2, tconv3, tconv4, tconv5 katmanları için sırasıyla sıfır, 1x0, 1x0, 1x0, 1x0 kırpma ve 1x0, 4x0, 4x0, 4x0, 2x0 adımlar (stride) kullanılmıştır. Tüm bn katmanları için, sıfıra bölmeyi önlemek ve sayısal kararlılığı garanti etmek için epsilon değerleri 1e-5 olarak ayarlanmıştır. Çizelge 3.4, ilgili adım ve kırpma parametrelerinin yanı sıra jeneratör ağına ait tüm katmanlara ait boyutları göstermektedir.

**Çizelge 3.4:** Jeneratör ağına ait tüm katmanlar ve bu katmanlara ait özellikler.

<b>Katman Kısaltması</b>	<b>Katman İsmi</b>	<b>Çıkış Boyutu</b>	<b>Parametreler</b>
Input	-	[1,1,100]	-
Proj-resh	Project and Reshape	[4,1,1024]	-
LInput	Label Input	[1,1,1]	-
Emb-resh	Embed and Reshape	[4,1,1]	-
Concat	Concatanetion	[4,1,1025]	-
Tconv1	Transposed Convolution	[8,1,1024]	Adım: [1,0] Kırpma: yok
Bn1	Batch Normalization	[8,1,1024]	-
Relu1	ReLU	[8,1,1024]	-
Tconv2	Transposed Convolution	[36,1,512]	Adım: [4,0] Kırpma: [1,0]
Bn2	Batch Normalization	[36,1,512]	-
Relu2	ReLU	[36,1,512]	-
Tconv3	Transposed Convolution	[150,1,256]	Adım: [4,0] Kırpma: [1,0]
Bn3	Batch Normalization	[150,1,256]	-
Relu3	ReLU	[150,1,256]	-
Tconv4	Transposed Convolution	[599,1,128]	Adım: [4,0] Kırpma: [1,0]
Bn4	Batch Normalization	[599,1,128]	-
Relu4	ReLU	[599,1,128]	-
Tconv5	Transposed Convolution	[120,1,1]	Adım: [2,0] Kırpma: [1,0]

Diskriminatör ağında, etiketler gömme ve yeniden şekillendirme katmanından geçirilir. Bu katmanın çıktısı ve giriş sinyalleri jeneratör ağına benzer şekilde bir birleştirme katmanı ile birleştirilir. Ancak diskriminatör kısmının geri kalanı jeneratörden farklılık göstermektedir. Bir conv (konvolüsyon) ve bir lrelu (leaky ReLU– sızan ReLU) aktivasyon fonksiyonu katmanından oluşan dört katman kümesi ve en sondaki çıkış katmanında tek halde bulunan bir conv katmanı bulunur. Denklem 3.2'de, conv katmanı aşağıdaki gibi formüle edilmiştir;

$$f(x) = \begin{cases} x < 0 & \text{için } \alpha x \\ x \geq 0 & \text{için } x \end{cases} \quad (3.2)$$

Burada,  $\alpha$  sabit gradyandır ve tüm konvolüsyon katmanları için conv 1x0 dolgulu bir çıktı katmanı kullanılmıştır. conv1, conv2, conv3, conv4, conv5 katmanları için sırasıyla; 2x0, 4x0, 4x0, 4x0, 1x0 adımlar kullanılmıştır. Diskriminatör ağının katman tanımları, çıktı boyutları ve parametreleri Çizelge 3.5'te gösterilmiştir. Her iki CGAN için kullanılan hiperparametreler ise Çizelge 3.6'da gösterilmiştir.

**Çizelge 3.5:** Diskriminatör'e ait katman yapısı ve bu katmanlara ait parametreler.

Katman Kısaltması	Katman İsmi	Çıkış Boyutu	Parametreler
Input	-	[1201,1,1]	-
LInput	Label Input	[1,1,1]	-
Emb-resh	Embed and Reshape	[1201,1,1]	-
Concat	Concatanetion	[1201,1,2]	-
Conv1	Convolution	[594,1,512]	Adım: [2,0] Dolgu: [1,0]
Lrelu1	Leaky ReLU	[594,1,512]	-
Conv2	Convolution	[146,1,256]	Adım: [4,0] Dolgu: [1,0]
Lrelu2	Leaky ReLU	[146,1,256]	-
Conv3	Convolution	[34,1,128]	Adım: [4,0] Dolgu: [1,0]
Lrelu3	Leaky ReLU	[34,1,128]	-
Conv4	Convolution	[8,1,64]	Adım: [4,0] Dolgu: [1,0]
Lrelu4	Leaky ReLU	[8,1,64]	-
Conv5	Convolution	[1,1,1]	Adım: [1,0] Dolgu: yok



**Çizelge 3.6:** CGAN eğitiminde kullanılmış hiperparametreler.

<b>Hiperparametreler</b>	
Öğrenme Oranı	0,0002
Gradyan bozunma faktörü	0,5
Mini grup boyutu	256
Dönem	500
Dönem başına iterasyon	7
Optimize edici	ADAM

### 3.5 Eğitim ve Performans Analizi


#### 3.5.1 Veri setinin hazırlanışı

Önerilen metodun pratikte ne kadar iyi performans gösterdiğini görmek için belirli testler yapılmıştır. 5 eksenli CNC makinesine bir ivmeölçer takılmıştır ve bu ivmeölçer ile titreşim verileri toplanmıştır. İki çalışma durumu (kararlı ve tırlama) simüle edilmiştir ve beraberindeki titreşim sinyalleri eğitim için veri seti olarak toplanmıştır. 1200 veri noktasına sahip bir sinyal tek örnek olarak kabul edilmiştir. İvmeölçer verileri, sentetik veri üretimi için CGAN'a ve sentetik verilerin tırlama algılamasına katkısını ölçmek için SVM'e girdi olarak verilmiştir.

2 bağımsız CGAN eğitimi için kullanılan tornalama sinyali veri seti iki alt gruptan oluşmaktadır. Bunlar ham sinyaller ve CEEMDAN algoritmasından elde edilmiş IMF'lerden ikinci mod olandır. CGAN eğitim veri seti, eşit sayıda alt bölüm örneği içerir ve toplam 3800 örnekten oluşmaktadır. SVM eğitimi ve testi için kullanılan tüm veri kümesi, 2400'ü kararlı durum ve 1600'ü tırlama durumu için olmak üzere toplam 4000 örnekten oluşmaktadır. Veri setinin farklı senaryo setlerinde kullanılmak üzere iki alt grubu bulunmaktadır. Bu bölümler ham örnekler ve CEEMDAN çıktıları örneklerden oluşur. Bu alt gruplar eşit sayıda ve 2000 örnekten oluşmaktadır. Bunlar eğitim ve test veri setleri olarak ikiye ayrılır. Her alt bölüm, bir eğitim seti ve farklı takım konumlarından örnekler içeren iki test seti içerir. Eğitim ve test için veri kümesi dağılımı 1:3 olarak belirlenmiştir.

### 3.5.2 CGAN eğitimi ve sentetik veri üretimi


Önerilen mimari kullanılarak gerçekçi sentetik örnekler oluşturulmuştur. Verilen modellerin üretim kapasitesini değerlendirmek için iki tür ivmeölçer verisi oluşturulmuştur. Sunulan mimaride, eğitim veri seti ve ilgili etiketler diskriminatör ağlarının girdisi olarak kabul edilmektedir ve aynı etiketler rastgele gürültü ile jeneratörlere girdi olarak sağlanmıştır. Her iki CGAN da 500 dönem boyunca eğitilmiştir. Her CGAN'daki her sınıf için 800 veri, toplamda 3200 sentezlenmiştir. Ham sinyal girişli CGAN ve CEEMDAN girişli CGAN aynı hiperparametrelerle eğitilmiştir. Her iki CGAN'ın jeneratör ve diskriminatör performansları, Şekil 3.9 ve Şekil 3.10'daki yitim grafiklerinde gösterilmektedir. Jeneratör yitimi, sahte örnek oluşturmadaki performansı gösterir. Ayırıcı yitimi ise, gerçek ve sahte örneklerin sınıflandırılmasındaki performansı gösterir. İterasyon sayısı arttıkça jeneratör yitiminin azalması ve diskriminatör yitiminin artmasının nedeni, jeneratörün gerçek örneklerin özelliklerini daha iyi öğrenmesi ve diskriminatörü yanıltmak için daha gerçekçi sinyaller üretmesidir.



**Şekil 3.9:** CGAN (ham sinyal girdisi) eğitim performansı a) jeneratör yitimi b) diskriminatör yitimi.


Benzer bir durum, her iki CGAN'nın iterasyon başına puan bilgisi veren puan grafikleri için de geçerlidir. Ham sinyal girdili CGAN için puan grafiği Şekil 3.11'de gösterilmektedir. CGAN için CEEMDAN girdisi olan diğer puan grafiği Şekil 3.12'de verilmiştir. CGAN eğitimi sırasında üretici ve ayırıcı arasındaki çekişme süreci bu şekillerde açıkça görülmektedir. Jeneratörün puan değeri arttıkça

diskriminatörün puanı azalır ve diskriminatörün puanı arttıkça jeneratörün puanı azalır.




**Şekil 3.10:** CGAN (CEEMDAN girdisi) eğitim performansı a) jeneratör yitimi b) diskriminatör yitimi.

İki ağ arasındaki bu çekişmeli süreçte her iki ağın kayıp değerlerinin Nash denge çizgisine yaklaştığı görülmektedir. Nash dengesi veya hiçbir ağın diğer ağın parametrelerini değiştirmeden maliyetlerini (cost) en aza indiremeyeceği konum, CGAN'ın hedefidir. Her iki ağ da bir Nash dengesi oluşturduğunda, CGAN yakınsar. Yukarıda belirtilen minimum-maksimum yitim denklemi için bu ideal konumdur. Maliyet değerleri düşürülür ve Nash dengesi konumunda hiçbir şeyin değiştirilmesi gerekmez. Diskriminatör, jeneratör tarafından üretilen sinyallerle kandırılmıştır ve her iki ağın da hedeflerine ulaşılmıştır.

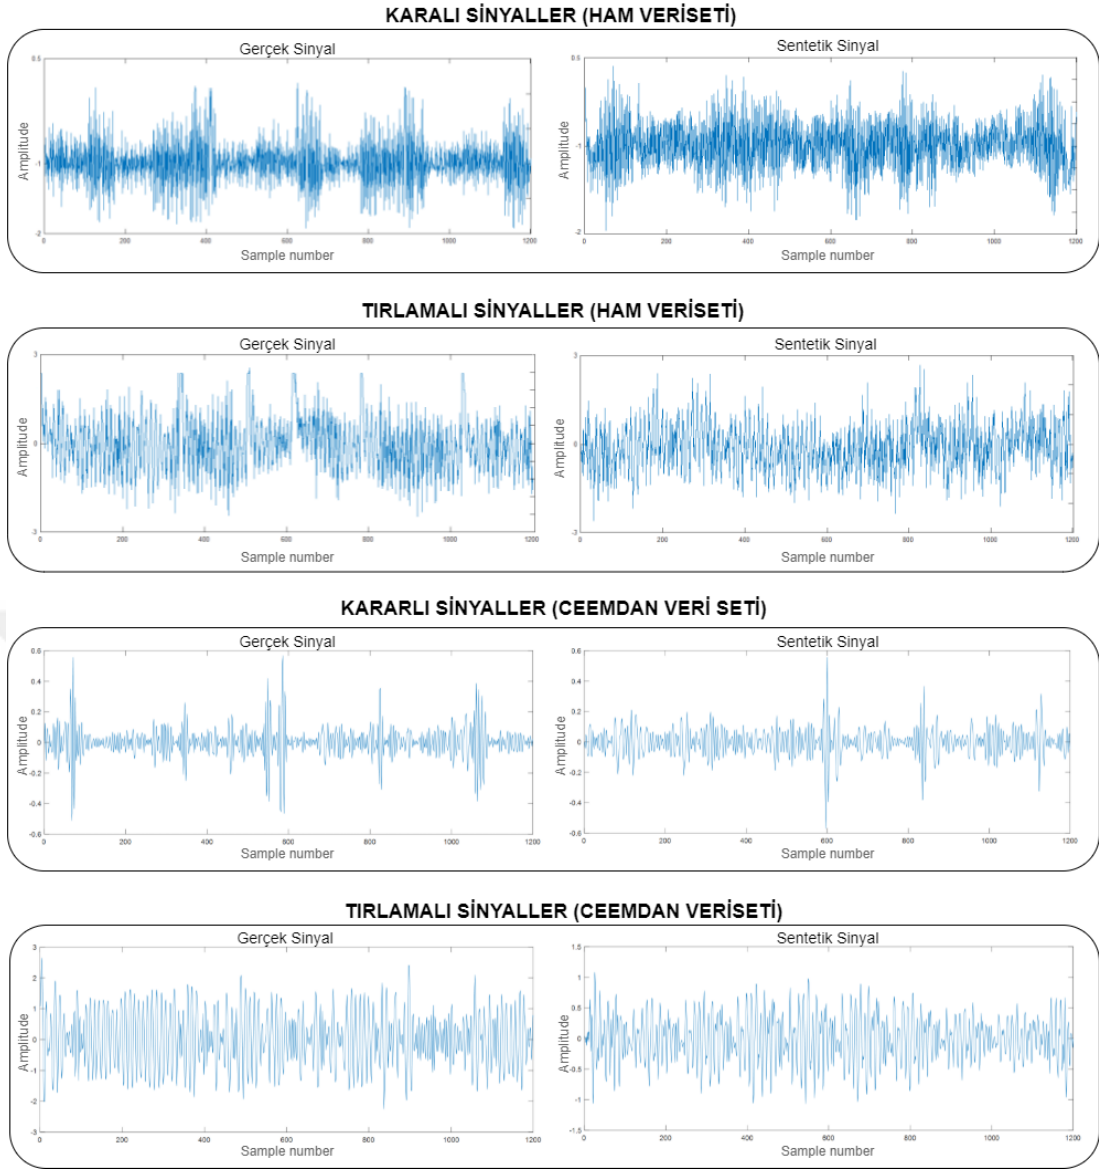


**Şekil 3.11:** Puan açısından CGAN (ham girdi ile) performansı.



**Şekil 3.12:** Puan açısından CGAN (CEEMDAN girdisi ile) performansı.

Önerilen tekniğin amacı, veri büyütme için gerçekçi sentetik örnekler oluşturmaktır. Hem ham hem de CEEMDAN veri kümeleri için oluşturulan sinyallerin kararlı ve tırlama durumlarının örnekleri, her bir örnekle eşleşen gerçek sinyallerle birlikte Şekil 3.13'te gösterilmektedir. Orijinal ve sentetik verilerin paternlerinin birbirine benzer olduğu görülmektedir. Üretilen verilerin ve gerçek titreşim sinyallerinin genellikle oldukça benzer olduğu açıktır. Bulgular, önerilen yaklaşımın gerçek sinyalin altında yatan kalıpları başarılı bir şekilde ortaya çıkarabileceğini ve veri artırma için makul sahte sinyaller üretilebileceğini göstermektedir.



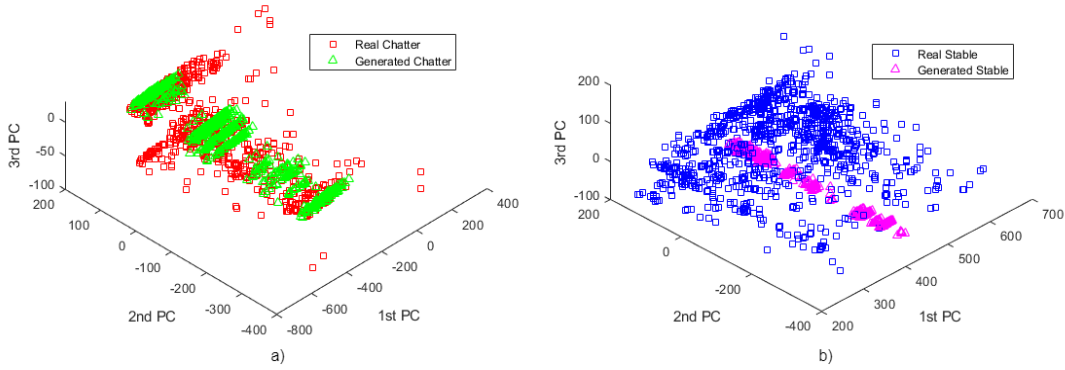
**Şekil 3.13:** Dört veri setinden gerçek sinyal örnekleri ile birlikte iki CGAN'dan aynı veri setleri girdi verilerek sentezlenmiş sentetik sinyal örnekleri.

### 3.5.3 PCA analizi


PCA matematiksel yaklaşımı, veri varyansının büyük çoğunluğunu değiştirmeden verilerin boyutunu düşürmek için kullanılır [80]. Bu azalma, verilerin varyansının en büyük olduğu birincil bileşenlerin (PC) bulunmasıyla sağlanır. Her örnek, az sayıda bileşen kullanılarak binlerce değiştirilebilir miktar yerine az sayıda değişken ile temsil edilebilir. Ardından, örneklerin ortak noktalarının ve karşıtlıklarının görsel olarak karşılaştırılmasına ve ayrıca örnek gruplamasının belirlenmesine izin verecek şekilde örnekler çizilebilir [81]. PCA tekniği, kararlı ve tırlama durumları için gerçek sinyallerin özellik dağılımını ve sentezlenmiş sinyallerin özellik dağılımını

görüntülemeyi amaçlayan görsel yorumlama için üç PC çıkarmak için tercih edilmiştir [82].

Gerçek ve sentetik (ham girdili CGAN'dan elde edilmiş) örneklerin özellik dağılım grafikleri Şekil 3.14'te gösterilmiştir. Gerçek ve sentetik (CEEMDAN girdili CGAN'dan elde edilmiş) örneklerin özellik dağılım grafikleri ise Şekil 3.15'te gösterilmiştir. Şekil 3.14 a)'ya bakıldığında gerçek ve sentetik tırlama PC'lerin birbirine yakın olduğu görülmektedir. Ancak, Şekil 3.14 b)'deki PC noktaları nispeten dağınık durumdadır. Şekil 3.15'e bakıldığında ise her iki dağılım grafiğinde de hemen hemen tüm noktaların birbirine çok yakın olduğu görülmektedir. Buradan, CEEMDAN ile ayrıştırılan sinyaller ve eğitilen CGAN ile üretilen sentetik sinyal özelliklerinin gerçek sinyallere çok yakın olduğu görülmüştür.



**Şekil 3.14:** Gerçek ve sentetik (ham girdili CGAN'dan elde edilmiş) örneklerin özellik dağılım grafikleri a) tırlama örnekleri b) kararlı örnekler.




**Şekil 3.15:** Gerçek ve sentetik (CEEMDAN girdili CGAN'dan elde edilmiş) örneklerin özellik dağılım grafikleri a) tırlama örnekleri b) kararlı örnekler.

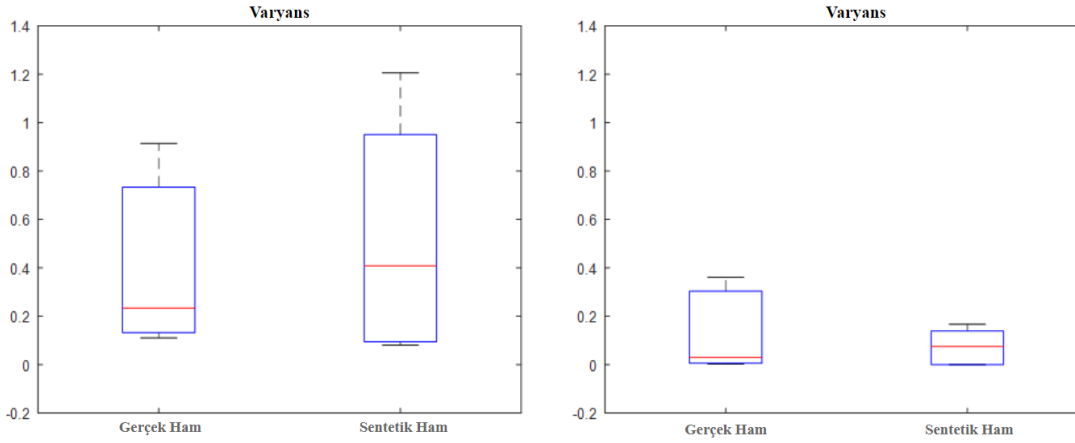
### 3.5.4 Veri üretiminin değerlendirilmesi

Önceki bölümlerde açıklanmış olan sentetik veri üretim süreçlerinin performansını test etmek için birtakım analizler yapılmıştır. Adım adım veri setindeki dengesizlik oranındaki azalmanın etkisinin test edilmesi amaçlanarak iki ana senaryo seti oluşturulmuştur. Birinci senaryo setinde, mevcut deneylerle elde edilen ham sinyallerin ve sinyal işleme yöntemlerinin girdi olarak verildiği ilk CGAN ile sentezlenen örneklerin test edilmesi amaçlanmaktadır. İkinci sette, ikinci CGAN ile üretilen, CEEMDAN algoritmasından geçirilen ve sinyallerin ikinci modları girdi olarak verilen örneklerin test edilmesi amaçlanmıştır. Her senaryo seti için 6 adet olmak üzere toplam 12 eğitim veri seti ve senaryo başına iki adet olmak üzere dört test seti oluşturulmuştur. Bu test setlerinden ilki, eğitim setleriyle aynı takım konumundan (aralıklı) elde edilen verilerden oluşmaktadır. İkincisi ise, eğitim verilerinden farklı bir takım konumunda (bitişik) yapılan kesimlerden elde edilen verilerle oluşturulmuştur.

Sentetik ve gerçek veriler arasındaki benzerliği değerlendirmek için istatistiksel göstergeler hesaplanmıştır. Öklid mesafesi ve varyans istatistiksel göstergeleri, sentetik ve gerçek titreşim sinyallerini karşılaştırmak için seçilmiştir. Bu iki istatistiksel gösterge için daha küçük değerler, örnekler arasında daha fazla benzerlik olduğunu gösterir. Her veri seti, sentetik numunelerin bütünlüğünü daha fazla incelemek için çok modlu üretme kapasitesini belirlemek için istatistiksel olarak analiz edilmiştir. Ham örnekler ve CEEMDAN çıktı veri kümeleri boyunca her kategori için istatistiksel göstergelerin kutu grafikleri Şekil 3.16 ve Şekil 3.17'de gösterilmektedir. Karşılaştırmalı sonuç, medyan tüm kategorilerdeki (ham sinyallerle eğitilmiş) istatistiksel göstergelerin ortalama değerini yansıttığından, CGAN2'nin (CEEMDAN çıktılar kullanılarak eğitilmiş) CGAN1'e karşı üstünlüğünü gösterir. Kutu grafiklerinin yüksekliği, iki istatistiksel gösterge grubunun birbirinden ne kadar ayrı olduğunu gösterir. Sonuçlar şu sonucu desteklemektedir; CEEMDAN veri üretimini büyük ölçüde etkiler, bu da performans açısından CGAN2'nin CGAN1'den neden daha iyi performans gösterdiğini açıklar.



**Şekil 3.16:** Farklı veri setlerine ait Öklid mesafesi değerlerine ait kutu grafikleri.



**Şekil 3.17:** Farklı veri setlerine ait varyans değerlerine ait kutu grafikleri.

İlk etapta her iki senaryo setinde 1:100 dengesizlik oranı, 8 tırlama ve 800 kararlı örneğe sahip veri seti ile SVM eğitimi gerçekleştirilmiştir. Daha sonra kararlı örnekler sabit tutularak CGAN'dan elde edilen sentetik verilerle tırlama örneklerinin sayısı belirli oranlarda artırılmıştır. 1:100'e ek olarak, dengesiz veri seti oranları sırasıyla 1:50, 1:20, 1:10, 1:5 ve 1:2 olarak belirlenmiştir. Toplam dört test veri seti için, her birinde 200 kararlı ve 200 tırlama olmak üzere toplam 1600 örnek kullanılmıştır. Senaryo kümeleri, Çizelge 3.7 ve Çizelge 3.8'de gösterilmiştir.



**Çizelge 3.7:** Birinci senaryo seti (ham veri seti için).

<b>Veri seti (Ham)</b>	<b>Takım Pozisyonu</b>	<b>Tırlamalı Örnekler</b>	<b>Kararlı Örnekler</b>	<b>Dengesizlik Oranı</b>
1	Ayrık	8	800	1:100
2	Ayrık	16	800	1:50
3	Ayrık	40	800	1:20
4	Ayrık	80	800	1:10
5	Ayrık	160	800	1:5
6	Ayrık	400	800	1:2
<b>Test Seti 1</b>	Ayrık	200	200	1:1
<b>Test Seti 2</b>	Bitişik	200	200	1:1

**Çizelge 3.8:** İkinci senaryo seti (CEEMDAN veri seti için).

<b>Veri seti (CEEMDAN)</b>	<b>Takım Pozisyonu</b>	<b>Tırlamalı Örnekler</b>	<b>Kararlı Örnekler</b>	<b>Dengesizlik Oranı</b>
1	Ayrık	8	800	1:100
2	Ayrık	16	800	1:50
3	Ayrık	40	800	1:20
4	Ayrık	80	800	1:10
5	Ayrık	160	800	1:5
6	Ayrık	400	800	1:2
<b>Test Seti 1</b>	Ayrık	200	200	1:1
<b>Test Seti 2</b>	Bitişik	200	200	1:1

Rastgelelikten kaynaklanabilecek herhangi bir yanlış sınıflandırma sonucunu önlemek için tüm eğitim ve test aşamaları 10 kere tekrarlanarak ortalama sınıflandırma yüzdeleri alınmıştır. SVM sınıflandırması için gerekli öznelikler aranırken, istatistiksel öznelikler arasından en iyi sonucu veren iki öznelik olarak RMS ve varyans kombinasyonu seçilmiştir. RMS, değişen niceliklerin büyüklüğünü ölçmek için kullanılan istatistiksel bir ölçüdür. Varyans ise verilerin aritmetik ortalamadan sapmalarının karelerinin toplamıdır. RMS ve varyans istatistiksel

özellikleri yakından incelendiğinde bu iki özelliğin neden özellikle iyi sonuçlar verdiğini anlamak mümkündür. RMS'in iyi sonuçlar vermesinin temel nedeni, kararlı bölgeden tırlama bölgesine geçiş yapıldığında sinyallerin RMS değerlerinin artmasıdır ve bu gösterge tırlamanın ana göstergelerinden biridir. Varyans, sinyalin ortalamadan ne kadar uzak olduğunun bir ölçüsü olan standart sapmanın karesidir. Varyans, bu dalgalanmanın gücünü temsil eder. Ayrıca, farklı takım konumlarından varyans değerleri bulunmuştur ve farklı özelliklere sahip sinyaller arasında bir bağlantı kurulmasına yardımcı olmuştur. Eğitim ve test işlemleri için oluşturulan veri setleri arasındaki bağlantıya katkı sağlamıştır. RMS ve varyans formülleri, sırasıyla Denklem 3.3 ve Denklem 3.4'te gösterilmiştir.

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N |x_n|^2} \quad (3.3)$$

$$Varyans = \frac{\sum_{i=1}^n (x_i - x)^2}{n - 1} \quad (3.4)$$


Dört farklı veri kümesinin sınıflandırma doğrulukları Çizelge 3.9'da gösterilmiştir.

**Çizelge 3.9:** Farklı senaryo setlerine ait sınıflandırma başarıları (%).

Veri seti (CEEMDAN)	Ayrık (Ham)	Ayrık (CEEMDAN)	Bitişik (Ham)	Bitişik (CEEMDAN)
1	81,00	81,90	51,25	83,25
2	100,00	100,00	69,75	99,90
3	100,00	100,00	89,55	100,00
4	100,00	100,00	96,05	100,00
5	100,00	100,00	96,45	100,00
<b>6</b>	100,00	100,00	98,50	100,00

Verilen tablolardan veri setlerindeki dengesizlik oranı azaldıkça sınıflandırma doğruluklarının arttığı görülmektedir. Ayrıca, aralıklı takım konumu veri kümesi ile eğitilen SVM bitişik takım konumu ile test edildiğinde bu doğruluk artışının devam ettiği gözlemlenmiştir. Elde edilen bu verilerle, bir takım konumu veri seti ile yapılan

bir eğitimin, farklı bir takım pozisyonu veri setinin tırlama durumunu tespit edebildiği gösterilmiştir. Bu durum ayrıca Şekil 3.18'den de gözlemlenebilir.



**Şekil 3.18:** Senaryo setleri için ortalama sınıflandırma doğrulukları.

Her veri seti için yapılan tüm testlerin sonuçlarının varyansları, 10 kere tekrarlanan test sonuçlarının güvenilirliğini belirlemek için hesaplanmıştır. Daha düşük varyanslar, daha iyi test güvenini gösterir. Bu sonuçlar Çizelge 3.10'da gösterilmiştir.

**Çizelge 3.10:** Tüm testlere ait güvenilirlik analizi için hesaplanan varyans değerleri.

Veri seti (CEEMDAN)	Ayrık (Ham)	Ayrık (CEEMDAN)	Bitişik (Ham)	Bitişik (CEEMDAN)
1	31,91	9,36	9,97	0,00
2	0,00	0,00	6,08	0,02
3	0,00	0,00	2,08	0,00
4	0,00	0,00	0,02	0,00
5	0,00	0,00	0,02	0,00
<b>6</b>	0,00	0,00	0,00	0,00



#### 4. SONUÇLAR

Makinelerde hata teşhisi ve tespiti konularında dengesiz veri dağılımı problemi oldukça sık karşılaşılan bir sorundur. Bu sorunun temel sebebi hata sınıflarındaki veri azlığından kaynaklanmaktadır. Torna tezgâhlarındaki tırlama titreşimi konusunda da aynı durum geçerlidir. Bu duruma yönelik en etkili çözüm yöntemlerinden biri yapay veri sentezidir. Derin öğrenme metodlarının da gelişmesi ile oldukça güçlü yapay veri sentez algoritmaları geliştirilmiştir. Bunlardan en etkili olanlarından biri GAN ve GAN türevi algoritmalarıdır.

Bu yüksek lisans tezi kapsamında, koşullu üretken çekişmeli ağları kullanarak dengesiz veri seti problemini çözmek için derin öğrenmeye dayalı sentetik veri üretimi ve tırlama tespit yöntemi önerilmiştir. Farklı veri setlerine özel CGAN'ler adapte edilerek farklı takım konumlarına ait sentetik veriler üretilmiştir. Üretilen bu sentetik veriler, belirli senaryolar ışığında birleştirilip sınıflandırma performansları incelenmiştir. Bu çalışma neticesinde aşağıdaki sonuçlar elde edilmiştir.

- Torna tezgâhında yapılacak kesim işlemlerine ait parametrelerin belirlenmesi amacı ile stabilite lob diyagramları kullanılmıştır. Bu diyagramlardan elde edilmiş parametrelerin sinyalleri etiketlemede büyük önem sahibi olduğu ve bu parametrelerin sinyal karakteristikleri üzerinde kritik önem taşıdığı görülmüştür.
- Standart GAN yapısının aksine satüre olmayan GAN yitimi kullanılmıştır ve bu sayede kaybolan gradyan probleminin önüne geçilmiştir.
- Çekişmeli eğitimlerde sıklıkla karşılaşılan mod çökmesini önlemek ve üretici ağın bu durumdan kaynaklanabilecek, yaratıcı çıktılar üretememesinin önüne geçilmesi amaçlanarak, jeneratör katmanlarındaki nöron sayısı diskriminatörün iki katına çıkarılarak bu duruma karşı çözüm elde edilmiştir.
- Gürültülü sinyallerden zayıf özneliklerin çıkarılmasında CEEMDAN'ın sinyal ayrıştırma yeteneklerinden yararlanarak, tırlama algılama alanında henüz başka bir örneği olmayan CEEMDAN'a dayalı bir ayrıştırma yaklaşımı önerilmiştir ve yapılan eğitimler sonucunda CEEMDAN kullanımının eğitim başarısını arttırdığı görülmüştür.

Gelecekteki çalışmalar için geliştirilen yöntemin frezeleme ve daha karmaşık işleme süreçlerine aktarılması planlanmaktadır. Ayrıca takım geometrisi, takım tezgâhı gibi operasyonel değişkenler değiştirildiğinde sentetik verilerin yeniden kullanımı araştırılacaktır. Bunlar ile birlikte, çalışma kapsamında kullanılan veri seti sadece tırlamalı ve tırlamasız veriyi içermekle birlikte, geçiş aşaması olan orta tırlama aşamasındaki sinyallerin endüstriyel kullanım için genel veri kümesine dahil edilmesi planlanmaktadır.



## KAYNAKLAR

- [1]. **Siddhpura, M., & Paurobally, R.** (2012). A review of chatter vibration research in turning. *International Journal of Machine tools and manufacture*, 61, 27-47.
- [2]. **Lei, Y.** (2016). *Intelligent fault diagnosis and remaining useful life prediction of rotating machinery*. Butterworth-Heinemann.
- [3]. **Dai, X., & Gao, Z.** (2013). From model, signal to knowledge: A data-driven perspective of fault detection and diagnosis. *IEEE Transactions on Industrial Informatics*, 9(4), 2226-2238.
- [4]. **Duan, L., Xie, M., Wang, J., & Bai, T.** (2018). Deep learning enabled intelligent fault diagnosis: Overview and applications. *Journal of Intelligent & Fuzzy Systems*, 35(5), 5771-5784.
- [5]. **Liu, R., Yang, B., Zio, E., & Chen, X.** (2018). Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, 108, 33-47.
- [6]. **Khan, S., & Yairi, T.** (2018). A review on the application of deep learning in system health management. *Mechanical Systems and Signal Processing*, 107, 241-265.
- [7]. **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.
- [8]. **Schmitz, T. L., & Smith, K. S.** (2009). *Machining dynamics*. Springer, 303.
- [9]. **Thusty, J.** (2000). *Manufacturing equipment and processes*. Thusty–NJ: Prentice–Hall, Upper Saddle River.
- [10]. **Taylor, F. W.** (1906). *On the art of cutting metals (Vol. 23)*. American society of mechanical engineers.
- [11]. **Arnold, R.** (1946). Cutting tools research: report of subcommittee on carbide tools: the mechanism of tool vibration in the cutting of steel. *Proceedings of the institution of mechanical engineers*, 154(1), 261-284.
- [12]. **Tobias, S. A., & Fishwick, W.** (1958). The chatter of lathe tools under orthogonal cutting conditions. *Transactions of the American Society of Mechanical Engineers*, 80(5), 1079-1087.
- [13]. **Thusty, J.** (1963). The stability of the machine tool against self-excited vibration in machining. *Proc. Int. Res. in Production Engineering*, Pittsburgh, ASME, 465.
- [14]. **Tobias, S. A.** (1965). *Machine-tool vibration*

- [15]. **Merrit, H. E.** (1965). Theory of self-excited machine-tool chatter. *Trans. ASME, J. Eng. Ind.*, 87(4), 447.
- [16]. **Tobias, S. A.** (1961). Machine tool vibration research. *International Journal of Machine Tool Design and Research*, 1(1-2), 1-14.
- [17]. **Wiercigroch, M., & Budak, E.** (2001). Sources of nonlinearities, chatter generation and suppression in metal cutting. *Philosophical Transactions of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 359(1781), 663-693.
- [18]. **Chen, Y., Li, H., Jing, X., Hou, L., & Bu, X.** (2019). Intelligent chatter detection using image features and support vector machine. *The International Journal of Advanced Manufacturing Technology*, 102(5), 1433-1442.
- [19]. **Rahimi, M. H., Huynh, H. N., & Altintas, Y.** (2021). On-line chatter detection in milling with hybrid machine learning and physics-based model. *CIRP Journal of Manufacturing Science and Technology*, 35, 25-40.
- [20]. **Huang, C. Y.** (2006). Analysis of process damping and system dynamics in milling (Doctoral dissertation, Ph. D. Thesis).
- [21]. **Das, M. K., & Tobias, S. A.** (1967). The relation between the static and the dynamic cutting of metals. *International Journal of Machine Tool Design and Research*, 7(2), 63-89.
- [22]. **Knight, W. A.** (1968). Application of the universal machinability chart to the prediction of machine tool stability. *International Journal of Machine Tool Design and Research*, 8(1), 1-14.
- [23]. **Tobias, S. A.** (1959). The vibrations of vertical milling machines under test and working conditions. *Proceedings of the Institution of Mechanical Engineers*, 173(1), 474-510.
- [24]. **Sadek, M. M., & Mills, B.** (1970). Effect of gravity on the performance of an impact damper: Part 1. Steady-state motion. *Journal of Mechanical Engineering Science*, 12(4), 268-277.
- [25]. **Ramaswami, R., Brussel, H. V., & Vanherck, P.** (1976). A Study on the Dynamic Machining of Free Machining Steel. In *Proceedings of the Sixteenth International Machine Tool Design and Research Conference* (pp. 377-384). Palgrave, London.
- [26]. **Wallace, P. W., & Andrew, C.** (1965). Machining forces: some effects of tool vibration. *Journal of mechanical engineering science*, 7(2), 152-162.
- [27]. **Kaymakci, M., Kilic, Z. M., & Altintas, Y.** (2012). Unified cutting force model for turning, boring, drilling and milling operations. *International Journal of Machine Tools and Manufacture*, 54, 34-45.
- [28]. **Altintas, Y.** (2000). *Manufacturing Automation* Cambridge University Press.
- [29]. **Tlusty, J.** (1986). *Dynamics of high-speed milling*.



- [30]. **Kayhan, M., & Budak, E.** (2009). An experimental investigation of chatter effects on tool life. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 223(11), 1455-1463.
- [31]. **Tlusty, J.** (1978). Analysis of the state of research in cutting dynamics.
- [32]. **Siddhpura, M., Siddhpura, A., & Bhave, S.** (2008). Vibration as a parameter for monitoring the health of precision machine tools. In *International Conference on Frontiers in Design and Manufacturing Engineering (ICDM)*, Coimbatore, India.
- [33]. **Armarego, E. J. A., & Brown, R. H.** (1969). *The machining of metals*. PRENTICE-HALL INC, ENGLEWOOD CLIFFS, N. J., 1969, 437 P.
- [34]. **Armarego, E. J. A., & Whitfield, R. C.** (1985). Computer based modelling of popular machining operations for force and power prediction. *Cirp Annals*, 34(1), 65-69.
- [35]. **Tlusty, J., & Andrews, G. C.** (1983). A critical review of sensors for unmanned machining. *CIRP annals*, 32(2), 563-572.
- [36]. **P.S. Heyns,** (2007) Tool condition monitoring using vibration measurements—a review, *Insight—Non Destructive Testing and Condition Monitoring* 49 447–450.
- [37]. **Zhu, K., San Wong, Y., & Hong, G. S.** (2009). Wavelet analysis of sensor signals for tool condition monitoring: A review and some new results. *International Journal of Machine Tools and Manufacture*, 49(7-8), 537-553.
- [38]. **Shanker, A.** (1976). An analysis of chatter vibration while turning slender workpieces between centres. *Annals of CIRP*, 25(1), 273-276.
- [39]. **Rahman, M., & Ito, Y.** (1985). Stability analysis of chatter vibration in turning processes. *Journal of Sound and Vibration*, 102(4), 515-525.
- [40]. **Bao, S. F., Zhang, W. G., Yu, J. Y., Qiao, S. M., & Yang, F. L.** (1994). A new approach to the early prediction of turning chatter.
- [41]. **Yeh, L. J., & Lai, G. J.** (1995). A study of the monitoring and suppression system for turning slender workpieces. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 209(3), 227-236.
- [42]. **Lin, S. C., & Hu, M. R.** (1992). Low vibration control system in turning. *International Journal of Machine Tools and Manufacture*, 32(5), 629-640.
- [43]. **Amin, A. K. M. N.** (1983). Investigation of the mechanism of chatter formation during metal cutting process. *Mech. Eng. Res. Bulletin*, 6(1), 11-18.
- [44]. **Tangjitsitcharoen, S., & Moriwaki, T.** (2008). Intelligent monitoring and identification of cutting states of chips and chatter on CNC turning machine. *Journal of Manufacturing Processes*, 10(1), 40-46.

- [45]. **Tangjitsitcharoen, S.** (2009). In-process monitoring and detection of chip formation and chatter for CNC turning. *Journal of Materials Processing Technology*, 209(10), 4682-4688.
- [46]. **Patwari, M. A. U., Nurul Amin, A. K. M., Faris, W. F., & Ishtiyag, M. H.** (2010). Investigations of formation of chatter in a non-wavy surface during thread cutting and turning operations. In *Advanced Materials Research* (Vol. 83, pp. 637-645). Trans Tech Publications Ltd.
- [47]. **Nurulamin, A. K. M., Jaafar, I. H., Patwari, A. U., & Zubaire, W. W. D.** (2010). Role of discrete nature of chip formation and natural vibrations of system components in chatter formation during metal cutting. *IIUM Engineering Journal*, 11(1), 124-138.
- [48]. **Tansel, I. N., Wagiman, A., & Tziranis, A.** (1991). Recognition of chatter with neural networks. *International Journal of Machine Tools and Manufacture*, 31(4), 539-552.
- [49]. **Zhang, C. L., Yue, X., Jiang, Y. T., & Zheng, W.** (2010). A hybrid approach of ANN and HMM for cutting chatter monitoring. In *Advanced Materials Research* (Vol. 97, pp. 3225-3232). Trans Tech Publications Ltd.
- [50]. **Bojja, P., Abraham, K., Varadarajan, S., & Prasad, M. G.** (2010, February). Experimental comparison of advance control strategies which use pattern recognition technique for nonlinear system. In *2010 Second International Conference on Machine Learning and Computing* (pp. 142-146). IEEE.
- [51]. **Du, R. X., Elbestawi, M. A., & Li, S.** (1992). Tool condition monitoring in turning using fuzzy set theory. *International Journal of Machine Tools and Manufacture*, 32(6), 781-796.
- [52]. **Zadeh, L. A.** (1978). Fuzzy sets as a basis for a theory of possibility. *Fuzzy sets and systems*, 1(1), 3-28.
- [53]. **Delio, T., Tlustý, J., & Smith, S.** (1992). Use of audio signals for chatter detection and control.
- [54]. **Li, X. Q., Wong, Y. S., & Nee, A. Y. C.** (1997). Tool wear and chatter detection using the coherence function of two crossed accelerations. *International Journal of Machine Tools and Manufacture*, 37(4), 425-435.
- [55]. **Gradisek, J., Govekar, E., & Grabec, I.** (1998). Time series analysis in metal cutting: chatter versus chatter-free cutting. *Mechanical systems and signal processing*, 12(6), 839-854.
- [56]. **Ji, Y., Wang, X., Liu, Z., Yan, Z., Jiao, L., Wang, D., & Wang, J.** (2017). EEMD-based online milling chatter detection by fractal dimension and power spectral entropy. *The International Journal of Advanced Manufacturing Technology*, 92(1), 1185-1200.
- [57]. **Zhang, Z., Li, H., Meng, G., Tu, X., & Cheng, C.** (2016). Chatter detection in milling process based on the energy entropy of VMD and WPD. *International Journal of Machine Tools and Manufacture*, 108, 106-112.

- [58]. **Sener, B., Gudelek, M. U., Ozbayoglu, A. M., & Unver, H. O.** (2021). A novel chatter detection method for milling using deep convolution neural networks. *Measurement*, 182, 109689.
- [59]. **Gao, S., Ren, Y., Zhang, Y., & Li, T.** (2021). Fault diagnosis of rolling bearings based on improved energy entropy and fault location of triangulation of amplitude attenuation outer raceway. *Measurement*, 185, 109974.
- [60]. **Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... & Liu, H. H.** (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, 454(1971), 903-995.
- [61]. **Wu, Z., & Huang, N. E.** (2009). Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Advances in adaptive data analysis*, 1(01), 1-41.
- [62]. **Yeh, J. R., Shieh, J. S., & Huang, N. E.** (2010). Complementary ensemble empirical mode decomposition: A novel noise enhanced data analysis method. *Advances in adaptive data analysis*, 2(02), 135-156.
- [63]. **Torres, M. E., Colominas, M. A., Schlotthauer, G., & Flandrin, P.** (2011, May). A complete ensemble empirical mode decomposition with adaptive noise. In *2011 IEEE international conference on acoustics, speech and signal processing (ICASSP)* (pp. 4144-4147). IEEE.
- [64]. **Wang, Y. R., Sun, G. D., & Jin, Q.** (2020). Imbalanced sample fault diagnosis of rotating machinery using conditional variational auto-encoder generative adversarial network. *Applied Soft Computing*, 92, 106333.
- [65]. **Jia, F., Lei, Y., Lu, N., & Xing, S.** (2018). Deep normalized convolutional neural network for imbalanced fault classification of machinery and its understanding via visualization. *Mechanical Systems and Signal Processing*, 110, 349-367.
- [66]. **Zhou, P., Hu, X., Li, P., & Wu, X.** (2017). Online feature selection for high-dimensional class-imbalanced data. *Knowledge-Based Systems*, 136, 187-199.
- [67]. **Liu, S., Jiang, H., Wu, Z., & Li, X.** (2021). Rolling bearing fault diagnosis using variational autoencoding generative adversarial networks with deep regret analysis. *Measurement*, 168, 108371.
- [68]. **Gourisaria, M. K., Agrawal, R., Harshvardhan, G. M., Pandey, M., & Rautaray, S. S.** (2021). Application of machine learning in industry 4.0. In *Machine Learning: Theoretical Foundations and Practical Applications* (pp. 57-87). Springer, Singapore.
- [69]. **Rezende, D., & Mohamed, S.** (2015, June). Variational inference with normalizing flows. In *International conference on machine learning* (pp. 1530-1538). PMLR.

- [70]. **Kingma, D. P., & Welling, M.** (2013). Auto-encoding variational bayes. arXiv preprint arXiv:1312.6114.
- [71]. **Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y.** (2014). Generative adversarial nets. *Advances in neural information processing systems*, 27.
- [72]. **Arjovsky, M., & Chintala, S.** (2017). L<sup>'</sup>eon Bottou., Wasserstein gan. arXiv preprint arXiv:1701.07875, 2(3), 5.
- [73]. **Metz, L., Poole, B., Pfau, D., & Sohl-Dickstein, J.** (2016). Unrolled generative adversarial networks. arXiv preprint arXiv:1611.02163.
- [74]. **Mirza, M., & Osindero, S.** (2014). Conditional generative adversarial nets. arXiv preprint arXiv:1411.1784.
- [75]. **Liu, J., Zhang, C., & Jiang, X.** (2022). Imbalanced fault diagnosis of rolling bearing using improved MsR-GAN and feature enhancement-driven CapsNet. *Mechanical Systems and Signal Processing*, 168, 108664.
- [76]. **Kuo, P. H., Luan, P. C., Tseng, Y. R., & Yau, H. T.** (2021). Nonlinear Chen-Lee Chaotic System Based Deep Convolutional Generative Adversarial Nets for Chatter Diagnosis.
- [77]. **Wang, Z., Wang, J., & Wang, Y.** (2018). An intelligent diagnosis scheme based on generative adversarial learning deep neural networks and its application to planetary gearbox fault pattern recognition. *Neurocomputing*, 310, 213-222.
- [78]. **Liu, H., Zhou, J., Xu, Y., Zheng, Y., Peng, X., & Jiang, W.** (2018). Unsupervised fault diagnosis of rolling bearings using a deep neural network based on generative adversarial networks. *Neurocomputing*, 315, 412-424.
- [79]. **Zhang, W., Li, X., Jia, X. D., Ma, H., Luo, Z., & Li, X.** (2020). Machinery fault diagnosis with imbalanced data using deep generative adversarial networks. *Measurement*, 152, 107377.
- [80]. **Jolliffe, I. T.** (2002). *Principal component analysis for special types of data* (pp. 338-372). Springer New York.
- [81]. **Ringnér, M.** (2008). What is principal component analysis? *Nature biotechnology*, 26(3), 303-304.
- [82]. **Jia, F., Lei, Y., Lin, J., Zhou, X., & Lu, N.** (2016). Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mechanical systems and signal processing*, 72, 303-315.