

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**FREZELEME İŞLEMLERİNDE MEYDANA GELEN TIRLAMA
TİTREŞİMLERİNİN DALGACIK DÖNÜŞÜMÜ VE KONVOLÜSYONEL SİNİR
AĞLARI İLE TESPİTİ**

YÜKSEK LİSANS TEZİ

Bathan ŞENER

Makina Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Hakkı Özgür Ünver

AĞUSTOS 2021

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.

Batıhan Şener

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**FREZELEME İŞLEMLERİNDE MEYDANA GELEN TIRLAMA
TİTREŞİMLERİNİN DALGACIK DÖNÜŞÜMÜ VE KONVOLÜSYONEL SİNİR
AĞLARI İLE TESPİTİ**

YÜKSEK LİSANS TEZİ

Bathan ŞENER

Makina Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Hakkı Özgür Ünver

AĞUSTOS 2021

ÖZET

Yüksek Lisans Tezi

FREZELEME İŞLEMLERİNDE MEYDANA GELEN TIRLAMA TİTREŞİMLERİNİN DALGACIK DÖNÜŞÜMÜ VE KONVOLÜSYONEL SİNİR AĞLARI İLE TESPİTİ

Batıhan Şener

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

Danışman: Doç. Dr. Hakkı Özgür Ünver

Tarih: Ağustos 2021

Frezeleme işlemi günümüz endüstrisinde en yaygın kullanılan talaşlı imalat yöntemlerinden biridir. Farklı tipleri olan tırlama titreşimleri, kesici takımların daha hızlı aşınmasına ve özellikle iş parçasındaki yüzey kalitesinin düşmesine sebep olarak, frezeleme işlemlerinin verimliliğine doğrudan zarar vermektedir. Tırlama, kesim sırasında iş parçası ile takım arasında oluşan kuvvetlerden dolayı meydana gelen anormal titreşimler olarak tanımlanabilmektedir. Tırlama, kesici takım tezgahının dinamik yapısına, iş parçasının ve takımın özelliklerine, proses parametrelerine bağlı olarak oluşmaktadır. Bu çalışma kapsamında freze işlemlerinde meydana gelen tırlama titreşimlerinin CNN modeli kullanılarak tespitini sağlayan özgün bir tırlama tespit yöntemi geliştirilmiştir. Yöntem kapsamında kendini yenileyen tırlama titreşimleri başarıyla etiketlenerek CNN modeli ile sınıflandırılmıştır. Freze işlemleri esnasında toplanan titreşim verileri, sistem özelliklerini değiştirmeyen ve kolayca sisteme bağlanabilen bir algılayıcı ile yapılmıştır. Deneylerde toplanan verilerin işlenmesinde tırlama titreşimlerinin doğrusal olmayan ve karmaşık yapısı göze alınarak, en gelişmiş sinyal işleme araçlarından biri olan dalgacık dönüşümleri kullanılmıştır. Dalgacık dönüşümleri ile elde edilen resimler CNN modeline girdi olarak verilmiştir. Sonuçlar irdelendiğinde farklı senaryolar için ortalama %99,88 düzeyinde bir tırlama sınıflandırma başarısı elde edilmiştir.

Anahtar Kelimeler: Kendini yenileyen tırlama, Frezeleme, Derin öğrenme,
Konvolüsyonel Sinir Ağları, Dalgacık Dönüşümleri



ABSTRACT

Master of Science Thesis

CHATTER DETECTION FOR MILLING BY USING WAVELET TRANSFORMS AND CONVOLUTIONAL NEURAL NETWORKS

Batıhan Şener

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

Supervisor: Assoc. Prof. Hakkı Özgür Ünver

Date: August 2021

Milling is one of the most widely used machining methods in today's industry. Different types of chatter vibrations directly affects the efficiency of milling operations by causing the cutting tools to wear faster and especially the surface quality of the workpiece to decrease. Chatter can be defined as abnormal vibrations that occur due to the forces between the workpiece and the tool during cutting. Chatter occurs depending on the dynamic structure of the cutting machine tool, the characteristics of the workpiece and the tool, and the cutting process parameters. Within the scope of this study, a novel chatter detection method has been developed that enables the detection of chatter vibrations in milling processes using the CNN model. In addition, self-renewing chatter vibrations were successfully labeled and classified with the CNN. During milling, vibration data are collected via a noninvasive data acquisition strategy. In the processing of the data collected in the experiments, wavelet transforms, one of the most advanced signal processing tools, were used considering the nonlinear and complex nature of chatter vibrations. Images that are obtained by wavelet transforms are given as inputs to the CNN model. When the results were examined, an average of 99.88% chatter classification accuracy was achieved for 3 different scenarios.

Keywords: Regenerative Chatter, Milling, Deep Learning, Convolutional Neural Networks, Continuous Wavelet Transform



TEŞEKKÜR

Çok değerli hocam, TÜBİTAK proje yürütücümüz ve yüksek lisans süresince danışmanım olan Doç. Dr. Hakkı Özgür Ünver'e bana karşı gösterdiği anlayışı, benimle paylaştığı tecrübeleri, hiçbir zaman benden esirgemediği desteği ve beni geleceğe hazırlamak için harcadığı emekleri için çok teşekkür ederim. Proje danışmanımız ve okulumuzun çok kıymetli hocası Doç. Dr. Murat Özbayoğlu'na, karşılaştığımız her sorunda bana yol gösterdiği için de ayrıca teşekkür ederim.

Bizlerle CUTPRO yazılımını ve çok değerli tecrübelerini paylaşarak destek olan Prof. Dr. Yusuf Altıntaş'a minnetlerimi sunarım.

Üniversitemizde yer aldığım süreç boyunca bana her zaman örnek olan çok kıymetli TOBB Ekonomi ve Teknoloji Üniversitesi hocalarıma ve bana burs imkanı sağlayan üniversiteme minnetlerimi sunarım. Bu tez çalışması TÜBİTAK 1001 programı (Proje no:118M414) tarafından desteklenmiştir.

Yüksek lisansım boyunca kendilerinden sayısız şey öğrendiğim, günlerimi beraber geçirdiğim çok sevgili arkadaşlarımdan başta Uğur Güdelek ve Fırat MEMU olmak üzere Olgun Utku GÜNGÖR, Muharrem AKKAYA'ya teşekkür ederim.

Kardeşim Doğuhan ŞENER'e, dostlarım İzzet AKOSMAN ve Can YEĞENOĞLU'na, değerli büyüğüm Suna KARAHAN'a tez yazma sürecimde bana olan desteklerinden dolayı minnet ve şükranlarımı sunarım.

Bugünlere gelmem için bana karşı gösterdikleri emeklerin karşılığını asla ödeyemeyeceğim çok sevgili Mine YILMAZ ŞENER ve Tayfun ŞENER'e ne kadar teşekkür etsem azdır.

Tez çalışmamı ise aydınlığıyla bana hep yol gösteren, bana her zaman güvenen, kıymetini anlatamayacağım merhum Türköz YILMAZ'a adıyorum.



İÇİNDEKİLER

	<u>Sayfa</u>
1. GİRİŞ	1
1.1. Problem ve Motivasyon	2
1.2. Tezin Katkıları	3
2. LİTERATÜR ARAŞTIRMASI VE ÖN BİLGİ	5
2.1. Frezeleme İşlemleri ve Frezeleme Dinamikleri	5
2.2. Takım Durumu İzleme	8
2.3. Tırlama Titreşimleri (Chatter)	12
2.3.1. Tırlama titreşimi tipleri	12
2.3.2. Tırlama titreşimlerinin kesici takım tezgahlarının performansına etkileri	13
2.4. Tırlama Titreşimlerinin Tespiti	15
2.4.1. Stabilite Lobları	21
2.5. Dalgacık Dönüşümleri	24
2.5.1. Sürekli dalgacık dönüşümleri (CWT)	25
2.6. Yapay Zeka Modelleri	27
2.6.1. Makine öğrenme	28
2.6.2. Derin öğrenme	29
2.7. Yapay Sinir Ağları	31
2.7.1. Konvolüsyonel Sinir Ağları (CNN)	32
2.7.1.1. Konvolüsyon katmanı	33
2.7.1.2. Havuz katmanı	34

2.7.1.3. Tam bağı katman	34
2.8. Tırlama Titreşimlerinin Yapay Zeka Modelleri ile Tespiti	34
2.8.1. Makine öğrenme yöntemleri ile tırlama tespiti	35
2.8.2. Derin öğrenme yöntemleri ile tırlama tespiti	36
2.8.3. Konvolüsyonel sinir ağları ile tırlama tespiti	36
3. DENEYSSEL YÖNTEM	39
3.1. Takım Tezgahının Dinamik Özelliklerinin Elde Edilmesi	40
3.1.1. Çekiç testi	42
3.1.2. Modal analiz	46
3.2. Stabilite Lobları	48
3.3. Kesme Verisi Toplama Sisteminin Hazırlanması	49
3.3.1. Veri toplama yazılımı	50
3.4. Tırlama Tespiti Analizi	51
3.4.1. Tez kapsamında geliştirilen özgün analiz metodu	52
3.4.2. Veri etiketlerinin belirlenmesi	53
3.5. CNN Model Mimarisi	56
4. DENEYSSEL ÇALIŞMALAR VE DEĞERLENDİRME	61
4.1. Kayıp Fonksiyonları ile Veri Setinin İrdelenmesi	61
4.2. Eğitim ve Doğrulama Senaryolarının Belirlenmesi	63
4.3. Model Performansının Literatürdeki Çalışmalar ile Karşılaştırılması	69
5. SONUÇLAR	71
6. KAYNAKLAR	73

ÖZGEÇMİŞ

Hata! Yer işareti tanımlanmamış.



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1: Yıllara göre tırlama ile ilgili yayın sayıları [2]	2
Şekil 2.1 Freze tezgahlarında temel parçalar	4
Şekil 2.2: Parmak Çevresel ve alın freze işlemlerinde kesici takım yönü ve hareketi	5
Şekil 2.3: Zıt ve eş yönlü frezelemenin kesici takım açısına etkileri	6
Şekil 2.4: Freze işlemlerinde radyal ve normal kuvvet yönleri	7
Şekil 2.5 Takım durumu izlemede kullanılan algılayıcılar ve yerleşimleri [5]	10
Şekil 2.6: Kendini yenileyen tırlamanın meydana gelişinde dış izleri ve takım dönüşü [9]	12
Şekil 2.7: Farklı operasyonlarda tırlama titreşimlerinin yüzey kalitesine etkisi [10]	13
Şekil 2.8: Durağan ve durağan olmayan durumlar [17]	17
Şekil 2.9: Zaman serisi ve frekans alanında titreşim sinyalleri a) kararlı durum (kesme derinliği 1mm), b) kararsız durum (kesme derinliği 2 mm), c) kararsız durum (kesme derinliği 3 mm) [18]	18
Şekil 2.10: Tlustý tarafından geliştirilen SLD örneği [27]	21
Şekil 2.11: Zamana bağlı sinyallerin işlemsiz halde, FFT, STFT ve dalgacık dönüşümlerinden sonra zamana ve frekansa göre çözünürlükleri	24
Şekil 2.12: Bir dalgacık üzerinde a parametresinin $\frac{1}{2}$ ve $\frac{1}{4}$ olarak seçimi [34]	26
Şekil 2.13: (a) Morlet dalgacık (reel kısım: düz çizgi. Sanal kısım: kesikli) kullanılarak elde edilen zamana göre değişen sinyal. (b) Değişken frekanslı test sinyali. (c) FFT güç spektrumu. (d) Sinyale uygulanan dalgacığın modu (siyahtan beyaza en düşükten en yüksek dalga büyüklüğüne doğru). (e) Dalgacığın sırt bölgesi. (f) Dalgacığın 3 boyutlu görüntüsü. (g) Dalgacığın 2 boyutlu görüntüsü [35]	27
Şekil 2.14: AI, makine öğrenme ve derin öğrenmenin veri büyüklüğü ve karmaşıklığı ile olan ilişkisi [3]	28
Şekil 2.15: Klasik AI ve derin öğrenme yöntemlerinin akış şemaları [43]	30
Şekil 2.16: Veri büyüklüğü ve model performansı ilişkisi [43]	30
Şekil 2.17: Derin öğrenme yöntemleri ve kullanım alanları [43]	31
Şekil 2.18: Derin öğrenmede kullanılan sinir ağı mimarisi [47]	32
Şekil 2.19: CNN mimarisinde yer alan katmanlar [43]	33
Şekil 2.20: Konvolüsyon katmanı operasyonları	33
Şekil 2.21: Maks - Havuzlama	34
Şekil 2.22: Farklı stabilite durumlarına ait dalgacıklar[55]	38
Şekil 3.1: Deneyler kullanılan 5 eksen freze tezgahı	39
Şekil 3.2: Çekiç testi esnasında çekiç ve ivmeölçerin yerleşimi	43
Şekil 3.3: Modal parametrelerin elde edilmesi [57]	43
Şekil 3.4: Çekiç testi neticesinde elde edilen eş zamanlı kuvvet(çekiç) ve ivme (ivmeölçer) verileri.	45
Şekil 3.5: Çekiç testi neticesinde elde edilen bağıdaşıklık grafiği	46
Şekil 3.6: Modal analiz esnasında seçilen noktalar	47
Şekil 3.7: Modal analiz sonucunda sisteme ait sanal ve gerçek büyüklük grafikleri	49

Şekil 3.8: Numerik çözüm ve Fourier seri açılımına dayalı analitik çözümden elde edilen SL	50
Şekil 3.9: Deney düzeneği	52
Şekil 3.10: Veri toplama işlemlerinde kullanılan Labview blok diyagramı	53
Şekil 3.11: Tırlama algılama yöntemine ait akış şeması [3]	54
Şekil 3.12: 10, 11 ve 12 nolu kesimler üzerinde tırlama yok, orta düzey tırlama ve yüksek düzey tırlamanın gösterilmesi.	56
Şekil 3.13 CNN Modeline ait mimari ve katman ölçüleri	59
Şekil 4.1: Tekli test ortamında kesimlerin kayıp değerleri	64
Şekil 4.2: S1 için SLD ve test kesimleri (sol), test kaybı dönem grafiği (sağ)	65
Şekil 4.3: S2 için SLD ve test kesimleri (sol), test kaybı dönem grafiği (sağ)	66
Şekil 4.4: S3 için SLD ve test kesimleri (sol), test kaybı dönem grafiği (sağ)	66
Şekil 4.5: S1 (sol) ve S1-WCP (sağ) senaryoları sonuçlarında karmaşıklık matrisleri	67
Şekil 4.6: S2 (sol) ve S2-WCP (sağ) senaryoları sonuçlarında karmaşıklık matrisleri	67
Şekil 4.7: S3 (sol) ve S3-WCP (sağ) senaryoları sonuçlarında karmaşıklık matrisleri	68

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 2.1: Takım durumu izlemede kullanılan algılayıcılar ve çıktıları.	9
Çizelge 3.1: Tezgah özellikleri.	39
Çizelge 3.2: Al 7075-T6 malzeme özellikleri.	41
Çizelge 3.3: Deneyleerde kullanılan kesici takım ucuna ait özellikler.	42
Çizelge 3.4: Kullanılan çekicinin teknik özellikleri.	44
Çizelge 3.5: Sisteme ait doğal frekans ve modal parametreler.	48
Çizelge 3.6: İvmeölçere ait teknik özellikler.	51
Çizelge 3.7: Deneyleere ait kesme parametreleri ve tırlama etiketleri.	57
Çizelge 3.8: CNN model mimarisi.	59
Çizelge 3.9: CNN hiper parametreleri.	61
Çizelge 3.10: CNN modeline ait pseude kod.	61
Çizelge 4.1: Senaryolara göre performans metriği değeri ve % doğruluk.	70
Çizelge 4.2: Geliştirilen CNN ile tırlama tespit yönteminin literatürdeki diğeri çalışmalar ile karşılaştırması.	72

KISALTMALAR

AI	Yapay Zeka (Artificial Intelligence)
ANN	Yapay Sinir Ağları (Artificial Neural Networks)
CCD	Şarj Çiftli Cihaz (Charge Coupled Device)
CNN	Konvolüsyonel Sinir Ağları (Convolutional Neural Networks)
CWT	Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)
DL	Derin Öğrenme (Deep Learning)
DMLP	Derin Çok Katmanlı Algılayıcı (Deep Multi-layer Preceptron)
FFT	Hızlı Fourier Dönüşümü (Fast Fourier Transform)
FRF	Frekans Cevap Fonksiyonu (Frequency Response Function)
GLCM	Eşzamanlı Gri Seviye Oluşumu (Grey Level Co-Occurrence Matrix)
HC	Yüksek Düzey Tırlama (High Chatter)
MC	Orta Düzey Tırlama (Medium Chatter)
ML	Makine Öğrenme (Machine Learning)
NC	Tırlama Yok (No Chatter)
SLD	Stabilite Lob Diyagramı (Stability Lobe Diagram)
STFT	Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform)
SVM	Destek Vektör Makineleri (Support Vector Machines)
VT	Voronoi Mozaiklenme (Voronoi Tessellation)
WCP	Kesme Parametreleri Kullanılarak (With Cutting Parameters)

1. GİRİŞ

Birinci sanayi devrimiyle birlikte seri üretim önem kazanmışken günümüzde algılayıcı (sensör) ve algılayıcılardan toplanan büyük verilerin AI yöntemleri ile birlikte kullanımının artması endüstri 4.0 kavramının ortaya çıkmasındaki etkenlerden biri olmuştur. Endüstri 4.0 kavramının yaygınlaşması, üretimde maliyetleri ve enerji kullanımını düşürmeyi, verimliliği ve kaliteyi artırmayı amaçlamaktadır. Özellikle imalat sanayindeki birçok endüstride; kalite, verimlilik, maliyet ve esneklik üzerinde sıklıkla çalışılan konular olmuştur. Havacılık/uzay, savunma, otomotiv ve biyomedikal sanayilerinde işleme zor olan metallerin çok yüksek yüzey kalitelerinde ve verimli olarak elde edilmesi amaçlanmaktadır [1]. Tırlama titreşimlerinin meydana gelmesi, bu amaçları engelleyen ciddi bir problemdir [2]. AI yöntemleri, endüstri 4.0 kapsamında bu amaçlara hizmet ve tırlama gibi karmaşık problemleri çözmekte kullanılabilir iyi araçlardan biri olarak karşımıza çıkmaktadır.

Bu yüksek lisans tezi kapsamında DMG-MORI™ DMU 65 Monoblok 5 eksen freze tezgahı üzerinde tırlama tespiti çalışmaları yürütülmüştür. Tırlama titreşimlerinin Stabilite Lobları üzerinden yapılan tırlama tespitinin, dalgacıklar üzerinden gözleme dayalı olarak yapılan tespit ile benzer olduğu gösterilmiştir. Bunun yanında kesme parametreleri gibi ek özelliklerin titreşim bilgisinin yanında CNN modeline verilmesinin, modellerin tırlama tespiti doğruluğunu arttırdığı ispat edilmiştir. Yapılan çalışmalar neticesinde verilerin en kolay şekilde toplanacağı bir ivmeölçer kullanılmış, tüm etiketleme süreci doğrudan kullanılan CNN modeline en uygun şekilde gerçekleştirilmiştir. Ayrıca CNN modelini kullanan çalışmalar arasındaki en yüksek tespit doğruluğuna ulaşmayı sağlayan, uygulaması çok daha basit bir yöntem geliştirilmiştir.


1.1. Problem ve Motivasyon

Problem:

Tırlama titreşimleri, talaşlı imalat süreçlerinin hemen hemen hepsinde sıklıkla karşılaşılan ciddi bir problemdir. Tırlama problemlerinin çözümü için ilk adım tırlama titreşimlerinin doğru olarak tespit edilmesidir. Tırlama tespitinin ardından tırlamayı meydana getiren kök nedenler anlaşılabilir ve bu nedenler ortadan kaldırılabilir. Tırlamanın tespiti, ileri düzeyde sinyal işleme bilgisi ve uzun süren bir inceleme safhası gerektirmektedir. İşte tam olarak bu noktada yapay zeka (AI) uygulamalarının tırlama tespit çalışmalarında kullanılması önem arz etmektedir. Tırlamanın yarattığı problemler ve bu problemlerin ortadan kaldırılmasının getireceği faydalar bölüm 2.3.2’de detaylı olarak verilmiştir.

Motivasyon:

Tırlama tespiti üzerine hali hazırda çok sayıda çalışma yapılmaktadır. Geçmiş yıllara bakıldığında ise 1966-2009 seneleri arasında artan bir şekilde çalışmaların yapıldığı görülmektedir. Yıllara göre tırlama konularında yapılan yayın sayıları Şekil 1.1’de gösterilmektedir.



Şekil 1.1: Yıllara göre tırlama ile ilgili yayın sayıları [2]

Özellikle AI uygulamalarının gelişmesiyle tırlama probleminin çözümünde AI kullanımı üzerine birçok çalışma yapılmıştır. Bu çalışmalar tez kapsamında incelenmiş ve bölüm 2.8’de anlatılmıştır. Özellikle CNN uygulamalarının tırlama tespitinde kullanımı noktasında eksikler bulunmaktadır. Yine var olan çalışmaların büyük çoğunluğu hem gerçek zamanlı olmaktan uzak hem de endüstriyel şartlarda

kullanılmayacak şekildedir. Bu tez çalışmasının motivasyonu tüm bu çalışmalar ve tırlama probleminin ciddiyeti dikkate alınarak, aşağıdaki şekilde sıralanabilir;

- Tırlama tespitinde CNN kullanılan çalışmalarda hem kullanılan algılayıcı tipi, hem de tırlamanın gözlemsel tespiti noktalarında endüstriyel uygunluk konusunda eksikler bulunmaktadır.
- CNN ile birçok derin öğrenme yöntemi kullanılarak yapılan tırlama tespit çalışmalarda eğitim ve test verileri arasındaki sızıntı dikkate alınmamıştır. Bu durum gerçek dünya uygulamalarında modellerin hiç görmediği parametrelerde gerçekleştirilmiş kesimlerde, tırlama titreşimlerini tespit etmesini mümkün kılmamaktadır.
- Tırlama tespitinde kullanılan CNN modellerinde girdi olarak yalnızca resimler kullanılmakta dolayısıyla kesme parametrelerinin taşıdığı bilgiden yararlanılmamaktadır.

1.2. Tezin Katkıları

Bahsi geçen problemlerin çözülmesi motivasyonu ile yapılan çalışmalar neticesinde literatüre freze işlemleri için yeni bir tırlama tespit yaklaşımı kazandırılmıştır [3]. Var olan tüm çalışmalardan farklı olarak;

- Modelin eğitim ve test verileri tamamen farklı kesimlerden elde edilmiştir. Bir kesim verisi kesimin hangi saniyesinde olursa olsun aynı etikete sahiptir. Bu durum geliştirilen yöntemin endüstriyel kullanımının önünü açmaktadır.
- İlk kez dalgacık kullanarak yapılan bir tırlama tespit çalışmasında, dalgacıklar üzerindeki değişimler, doğrudan çekiç testi sonuçları ile bağdaştırılarak tırlama tespiti yapılmıştır. Tırlamanın içgüdüsel olmayan, kesme hızına göre artıp azalma durumu dalgacıklar üzerinde de ispat edilmiştir.
- CNN ile tırlama tespiti yapılan çalışmalar içerisinde ilk kez kesme parametreleri de modele girdi olarak verilerek çok sayıda farklı fırsatın önü açılmıştır.
- Literatürde ilk kez ucuz ve kolay uygulanabilir bir ivme ölçerden elde edilen dalgacıkların bir CNN modeline sokulması ile sonuç alınmıştır.




2. LİTERATÜR ARAŞTIRMASI VE ÖN BİLGİ

Bu bölümde, tez kapsamında geliştirilen özgün turlama tespit yönteminin geliştirilme aşamasında kullanılan tüm teknikler, bu tekniklerin hangi çalışmalar sayesinde geliştirildiği ve bu teknikleri anlamak üzere bilinmesi gereken temel konular verilmiştir.


2.1. Frezeleme İşlemleri ve Frezeleme Dinamikleri

Freze işlemleri, talaşlı imalat yöntemleri içerisinde en yaygın olarak kullanılan işlemlerden biridir. Torna işlemlerinin aksine ekseriyetle iş parçasının sabit durması ve kesici takımın hareketi ile iş parçasına şekil verilir. Kesici takım genellikle bir takım tutucuya bağlanır. Takım tutucu ise iş miline bağlanarak, iş milinde gerçekleşen dönüş hareketini kesici takım vasıtası ile iş parçasına aktarır. En az 3 eksene sahip olmakla birlikte 5 eksen kabiliyetine sahip freze tezgahları da bulunmaktadır. Tipik bir freze işlemine ait görsel Şekil 2.1’de gösterilmektedir.



Şekil 2.1 Freze tezgahlarında temel parçalar


Freze işlemlerinde kesici ucun tipi ve iş parçasına göre hareketine bağlı olarak farklı işlemler tanımlanabilmektedir. Parmak freze tipleri ise Şekil 2.2’de verilmektedir.



Şekil 2.2: Parmak Çevresel ve alın freze işlemlerinde kesici takım yönü ve hareketi

Çevresel frezeleme işlemlerinde kesici ucun dönme eksenini ve iş parçasının yüzeyi birbirine paraleldir. Dolayısıyla kesme işlemi kesici takımın çevresinde yer alan kesici uçlar boyunca gerçekleşir. Çevresel frezeleme işlemlerinde temel farkı, kesici ucun dönüş yönü ve takımın ilerleme yönü arasındaki ilişki belirler. Saat yönü ve saat yönünün tersi olmak üzere iki farklı şekildedir. Bu tipler Şekil 2.3'te verilmiştir.

Dönme yönünün ilerleme yönüne göre farklı, en temelde talaş oluşumunu etkilemektedir. Talaşın oluşum şekli, kesme esnasında meydana gelen kuvvetleri de belirlemektedir. Bu durumda tırlama titreşimlerinin matematiksel ifadeleri için talaş oluşumunun modellenmesi gerekir. Talaşın oluşum şeklini matematiksel olarak hesaplamak için ise ilk olarak kesici takımın iş parçasıyla olan etkileşimini modellemek gerekir. Bu model kurgulanırken ilk adım kesici takımın iş parçası içindeki açısal hareketini hesaplamaktır. Burada ϕ açısı giriş ve çıkış için ayrı ayrı belirlenir. Şekil 2.3'te ϕ açılarının çevresel frezeleme tiplerine göre farkları gösterilmiştir.



Şekil 2.3: Zıt ve eş yönlü frezelemenin kesici takım açısına etkileri

Talaş formasyonu (h) değerleri için kesici takım ucunun giriş ϕ_s ve çıkış ϕ_e açısı değerlerinin bilinmesi gerekir. Yukarı yönlü frezeleme işleminde giriş açısı 0 olmakla beraber çıkış açısı kesme parametreleri olan yan kayma (a) ve takım yarıçapı (r) değerlerine bağlıdır. Bu bağıntı eşitlik 2.1’de verilmiştir.


$$\phi_e = \cos^{-1} \left(\frac{r-a}{r} \right) \quad (2.1)$$

Aşağı yönlü frezeleme işleminde ise çıkış açısı 180 derecedir. Başlangıç açısı değeri ise yukarı yönlü freze işlemlerinde olduğuna benzer şekilde yan kayma ve takım yarıçapına bağlıdır. Bu bağıntı eşitlik 2.2’de verilmiştir.

$$\phi_s = 180 - \theta = 180 - \cos^{-1} \left(\frac{r-a}{r} \right) \quad (2.2)$$

Bölüm 2.4.1 içerisinde verilecek olan tırlamaya etki eden kesme kuvveti hesaplarında kullanılacak olan notasyonlar ise Şekil 2.4’te verilmiştir. Eşitlik 2.1 ve 2.2 içerisinde verilen giriş ve çıkış açıları Şekil 2.4’te gösterilen kuvvetlerin hesaplamasında yine

bahsi geçen kısımda verilmiştir. Tez boyunca yapılan hesaplarda bu notasyon kullanılmıştır.



Şekil 2.4: Freze işlemlerinde radyal ve normal kuvvet yönleri

2.2. Takım Durumu İzleme

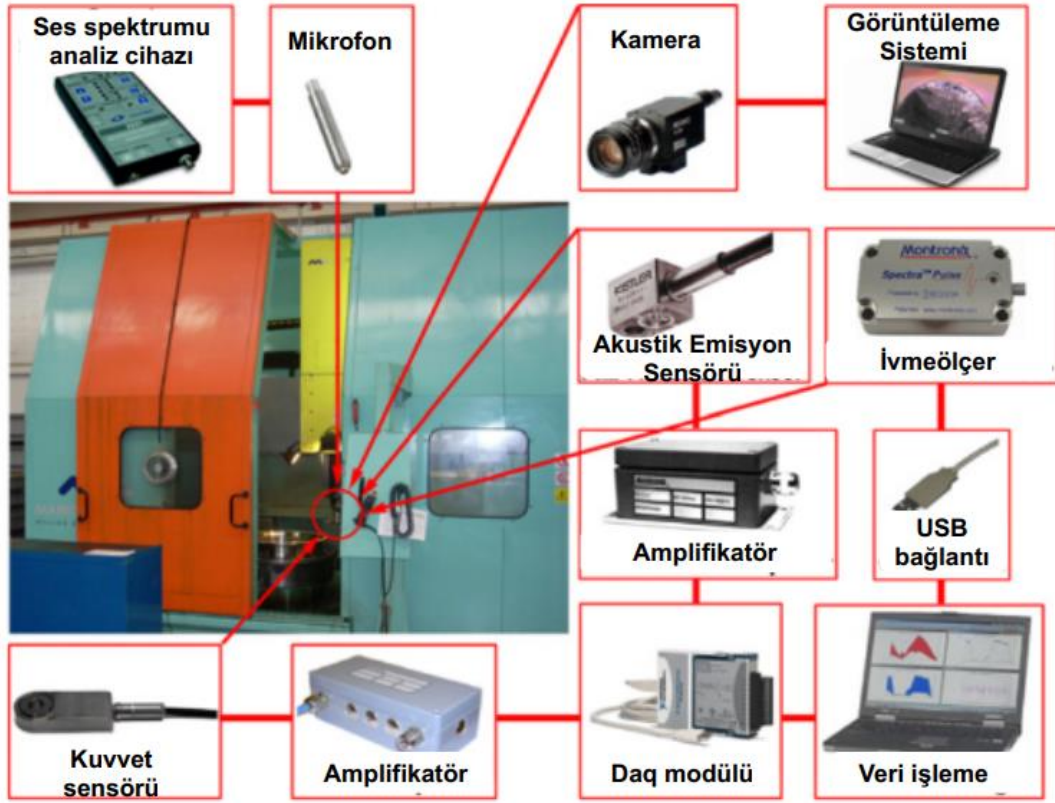
Takım durumunu izleme, kesici takımında meydana gelebilecek hataların önceden tahmin edilerek ileride meydana gelebilecek daha büyük sıkıntıların ve maliyetlerin önüne geçmesi açısından çok kritiktir. Kesici takımında meydana gelebilecek hatalar, takımın kırılması ve aşınması olarak ikiye ayrılır. Bu hataları tespit edebilmek için literatürde genellikle doğrudan ve dolaylı ölçüm sistemleri olarak iki farklı yöntem uygulanır. Doğrudan ölçüm yöntemlerinde kesici takımında veya üretilen parçadaki boyutsal değişiklikler kameralarla doğrudan tespit edilir. Örneğin, doğrudan gözetleme sistemlerinde, mikroskop veya yüzey profilometresi kullanılarak kesici takımında meydana gelen anormallikler doğrudan tespit edilir. Bu ölçüm yönteminde hata meydana gelebilecek yüzeyler manuel olarak gözlemlendiği için daha hassas sonuçlar elde edilmektedir. Bununla birlikte bu ölçüm yönteminin dezavantajı, takım tezgahının çalışma ortamında yer alan optik cihazların doğruluğu ve hassasiyeti bozulabilmektedir ve bu yöntemle veri toplayabilmek için kesim işlemi sürekli durdurulması gerekir. Dolayısıyla üretim süresi ve üretilen parçanın kalitesi bundan olumsuz etkilenir.

Doğrudan ölçüm yöntemlerinin aksine, dolaylı ölçüm yöntemlerinde, takım aşınması ve takım kırılması gibi kesici takımda meydana gelebilecek durumlar, titreşim, sıcaklık, kesme kuvveti ve akustik emisyonlardan (AE) kaynaklanan sinyaller kullanılarak gözlemlenir. Başka bir ifadeyle, dolaylı ölçüm sistemlerinde Şekil 1.2’de gösterilen donanım bileşenleri olarak kameralar yerine farklı algılayıcı tipleri kullanılır. Ölçüm doğruluğu doğrudan yöntemlerden daha düşük olmasına rağmen, talaşlı imalat sırasında veri toplaması daha hızlı ve kolaydır. Ayrıca bu yöntem kesici takımın durumunu belirlemede daha hassas veri toplar ve gerçek-zamanlı (real-time) gözetleme yapabilmeye olanak sağlar. Takım durumu izleme işlemlerinde kullanılan algılayıcılar ve çıktıları Çizelge 2.1’de verilmiştir.

Doğrudan görüntü işleme tabanlı ölçüm yöntemleri, daha düşük maliyetlerinden dolayı literatürdeki eski çalışmalarda daha fazla tercih edilmiştir. Dutta vd. tornalama işleminde gitgide artan yanal takım aşınmasını tahmin edebilmek amacıyla bir yöntem geliştirmişlerdir. Geliştirdikleri tahmin modelinde talaşlı imalat sonrasında kesici takımın parça yüzeyi üzerinde bıraktığı izler, dalgalanmalar ve pürüzlülükler voronoi mozaikleme (Voronoi Tessellation) (VT), gri-seviyeli eş oluşum matrisi (grey level co-occurrence matrix) (GLCM) ve ayırık dalgacık dönüşümü (discrete wavelet transform) yöntemleri kullanılarak takımda meydana gelen yanal aşınma görüntüleri görüntü işleme prosesi uygulayabilmek için ön işleme (pre-processing) tabii tutulmuştur. Daha sonra elde edilen görüntüler, destek vektör makinası (support vector machine) (SVM) yöntemi sayesinde kesici takımın durumunu tahmin edecek şekilde sınıflandırılmıştır [4].

Çizelge 2.1: Takım durumu izlemede kullanılan algılayıcılar ve çıktıları.

Takım durumu izleme	Proses parametreleri (Giriş sinyali)	Ölçüm cihazları	Çıktı sinyalleri
Doğrudan	Optik	CCD kamera veya optic sensörler	Takım aşınmasının boyutu ve yoğunluğu
	Elektrik direnci	Voltmetre	Takım ve iş parçası arasındaki bağlantı direnci
	Deplasman	Mikrometre, pnömatik ölçer, deplasman transdüser	Takım ve iş parçası arasındaki mesafe
	Akustik emisyon	Akustik emisyon transdüseri, mikrofön	Akustik dalga
Dolaylı	Titreşim	İvmeölçer	Takım ve iş parçası arasında meydana gelen titreşimler
	Kesme kuvveti	Dinamometre veya gerginlik ölçer	Talaşlı imalat sırasında iş mili üzerindeki kesme kuvveti
	Kesme sıcaklığı	Isıl çiftler (<i>thermocouple</i>)	İş parçasının veya iş milinin sıcaklığı
	Elektrik akımı	Ampermetre veya dinamometre	Makinanın çektiği güç veya tüketilen enerji
	Yüzey pürüzlülüğü	CCD kamera veya fiber optic sensör	Parçanın yüzey pürüzlülüğü



Şekil 2.5 Takım durumu izlemede kullanılan algılayıcılar ve yerleşimleri [5]

Tornalama veya frezeleme işlemlerinde, kesme derinliği (mm) ve iş mili hızı (dv/dk) proses parametrelerine bağlı olarak kesici takım ile iş parçası arasında meydana gelen güçlü bağıl titreşimden dolayı tırlama titreşimi meydana gelir. Burada meydana gelen tırlama titreşimi kesici takımın ömrünü azaltmaya ve parçanın da yüzey kalitesinin kötü çıkmasına sebep olur. Bu amaç doğrultusunda, kesici takımın durumunu ve prosesi izlemenin en yaygın yollarından biri iş milinin üzerine bağlanan ivmeölçer yardımıyla titreşim verilerinin toplanmasıdır. İş parçası üzerindeki istenmeyen düzensiz takım yolu izin ve rahatsız edici sesler, aşırı titreşim nedeniyle oluşur. Bu durum, yüzey kalitesinin bozulmasına, takım ömrünün azalmasına, takımın daha hızlı aşınmasına ve takımın kırılmasına neden olur. Teti vd.'ne göre iki farklı titreşim türü vardır. Bunlar, bağımlı ve bağımsız titreşimlerdir. Bir kesici takım tezgahı, balansı bozulmuş bileşenler, karşılıklı parçaların atalet kuvvetleri ve sürücülerdeki kinematik arızalar sebebiyle bağımsız titreşimlere maruz kalır. Başka bir ifadeyle, proses parametreleriyle ilgisi olmayan faktörler bağımsız titreşimleri tetikler. Bununla birlikte, proses parametrelerindeki değişiklikler ise bağımlı titreşimlere neden olur [5].

2.3. Tırlama Titreşimleri (Chatter)


Tırlama titreşimleri, talaşlı imalat süreçlerinde sıklıkla karşılaşılan ciddi bir problemdir. Tırlama, kesici takım tezgahının dinamik özelliklerine, iş parçasının ve takımın özelliklerine, proses parametrelerine bağlı olan ve kesim sırasında iş parçası ile takım arasında oluşan kuvvetlerin kararsız hale gelmesinden dolayı meydana gelen anormal titreşimler olarak tanımlanabilmektedir.

Tırlama titreşimleri genellikle birincil ve ikincil olmak üzere iki kategoride sınıflandırılır: Birincil tırlama, kesme işleminin kendisinden kaynaklanabilir (yani, takım ile iş parçası arasındaki sürtünme, talaş oluşumu üzerindeki termo-mekanik etkiler veya titreşim dinamikleri). İkincil tırlama ise, iş parçası yüzeyindeki dalgalanmalar ile temas eden kesici takımın titremesi sebebiyle oluşmaktadır. Bu yenileyici etki, tırlamanın en önemli sebeplerinden biri olarak kabul edilmektedir. Dolayısıyla “tırlama”nın sadece kendini yineleyen tırlamayı ifade ettiği bir gelenek haline gelmiş ve birçok yayın bu kabul üzerinden yapılmıştır. Bir diğer yandan, tırlama titreşimlerine neden olan kendini yenileyen etkileşim mekanizmaları dört tip olarak ayrılabilir. Bunlar; sürtünmeden kaynaklanan tırlama, termo-mekanik tırlama, mod eşleşmesinden (*mode coupling*) kaynaklı tırlama ve kendini yineleyen (*regenerative*) tırlamadır [2].

2.3.1. Tırlama titreşimi tipleri

- Sürtünmeden kaynaklı tırlama: Kesici takım ile iş parçası arasındaki küreme yüzeyinde meydana gelen sürtünme sebebiyle, kesme kuvvetli yönünde artan titreşimler olarak gözlemlenir [6].
- Termo-mekanik tırlama: Talaş oluşumu esnasında meydana gelen plastik deformasyon bölgelerindeki sıcaklıklar sebebiyle meydana gelen titreşimler olarak gözlemlenir [7].
- Mod eşleşmesinden kaynaklı tırlama: Kesici takım ucunun ilerleme yönünde gerçekleşen titreşimlerin kesme kuvvetlerinin yönünde gerçekleşen titreşimlere etkisi veya bu durumun tam tersinin gerçekleşmesi şeklinde gözlemlenir. Bu durum hem kesme yönünde hem de ilerleme yönünde eş zamanlı olarak titreşimlere sebep olur [2].
- Kendini yenileyen tırlama: Tırlama titreşiminin en yaygın şekli kendini yenileyen tırlama titreşimi (*regenerative chatter*)’dır. Bu tip tırlama

titreşiminin sebebi kesici takımın yüzeydeki dalgalanmalarla olan etkileşimidir. Bir frezeleme işlemi esnasında, parçaya doğru yaklaşan kesici takım ucu (j), bir önceki ucun (j-1) bırakmış olduğu iz ile etkileşime girebilmektedir. Bu etkileşimin sonucunda titreşimlerin büyüklüklerinde ciddi artışlar meydana gelebilmektedir. Şekil 2.6’da kesici takımın iş parçası yüzeyi ile olan etkileşiminin modeli gösterilmektedir. Burada kesici takım 2 serbestlik dereceli bir sistem olarak betimlenmiştir. F_{rj} ve F_{tj} kesim esnasında iş parçası ile temasta olan kesici uç üzerinde oluşan radyal ve normal kuvvetleri temsil etmektedir. Genel olarak tırlama titreşimi, takım tezgahındaki dengesizliklerden kaynaklanmaktadır. Belirli bir kesme hızı ve yanal kayma değerinde, aksel kesme derinliği dengeli kesimin gerçekleşmesinde en önemli faktördür. Tekeli ve Budak, bir freze işleminde; eğer kesme derinliği dengeli alanın dışarıdaysa seçilen ilerleme hızı ve kesme hızı gibi parametreler uygun olsa dahi işlem sırasında tırlama oluşma ihtimalinin oldukça yüksek olacağını belirtmişlerdir [8].

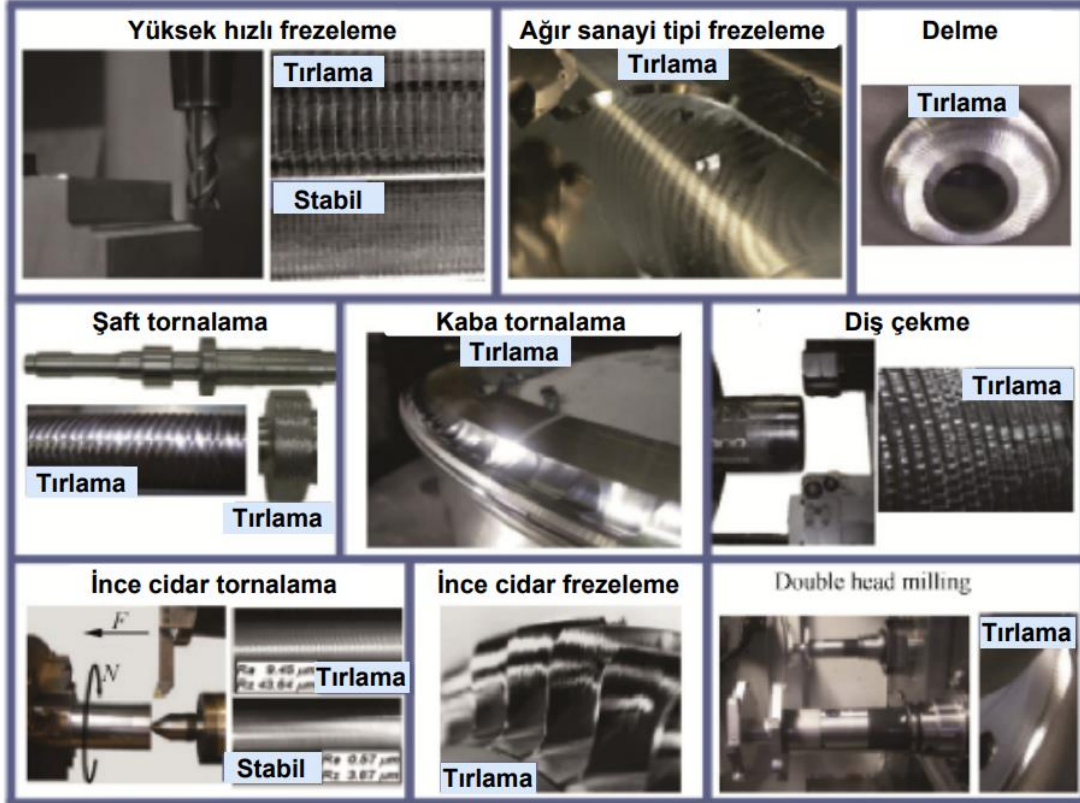


Şekil 2.6: Kendini yenileyen tırlamanın meydana gelişinde diş izleri ve takım dönüşü [9]

2.3.2. Tırlama titreşimlerinin kesici takım tezgahlarının performansına etkileri

Tırlama titreşimleri meydana geldikleri kesim süresince birçok ayrı noktadan işlem performansına etki eder. Kesim esnasında meydana gelen bu kararsız durum, özellikle yüzey kalitesinin düşmesine neden olur. İş parçaları toleransların dışında yüzey pürüzlülüğü değerlerine sahip olabilmekte ve buna bağlı olarak kullanılmaz hale

gelebilmektedir. Meydana gelebilecek yüksek kesme kuvvetleri neticesinde kesici takımlar, takım tutucular ve takım tezgahlarında da bozulmalar meydana gelebilir. Kimi durumlarda kesici takım kırılmaları meydana gelerek güvenlik riski dahi oluşturabilir. Şekil 2.7’de çıktı parçalarında tırlamadan kaynaklı ortaya çıkan yüzey kalitesi problemleri gösterilmektedir.



Şekil 2.7: Farklı operasyonlarda tırlama titreşimlerinin yüzey kalitesine etkisi [10]

Maliyet çerçevesinden incelendiğinde ise tırlama titreşimlerinin meydana gelmesi, kesim esnasında iş mili üzerine daha çok yük bindirmekte ve tezgahın enerji tüketimini arttırmaktadır. Tırlama titreşimleri oluştuğunda kesici takımların daha hızlı aşınmasına sebep olduğundan, uç değiştirme sıklığı artacak dolayısıyla sarf ve işçilik maliyetlerinde yükselmeye sebep olacaktır. Özellikle kullanılmaz hale gelen iş parçaları hem malzeme israfına hem de işlemin tekrarından kaynaklı zaman kaybına sebebiyet verebilmektedir.

Tırlamadan kaçınmak üzere belirlenen kesme parametreleri işlem sürelerini uzatmaktadır. Tırlamanın karmaşık yapısından dolayı güncellemesi gereken kesim parametreleri çoğu zaman içgüdüsel olmadığından, yanlış şekilde güncellenen parametreler daha kararsız kesimlere sebep olabilmektedir. Bunların yanında

tırlamanın meydana geldiği işlemlerde bu titreşimlerin kök nedenlerinin analiz edilmesi, nitelikli personel tarafından yapılırsa dahi oldukça zaman almaktadır. Tüm bu sebepler göz önüne alındığında, tırlamanın bütün kesici takım işlemlerinde ciddi maliyet artışlarına sebebiyet verdiği kabul edilmektedir. Renault tarafından yapılan bir çalışmada 2 litre hacmindeki dizel motorlarda, tırlamadan kaynaklı ünite başına ek maliyet 0,35 avro olarak belirlenmiştir. Firmanın bu üniteden 3 milyon adet ürettiği düşünüldüğünde, tırlama kaynaklı maliyetlerin büyüklüğü anlaşılmaktadır [11].

Sonuç olarak kesici takım işlemlerinde tırlamanın olumsuz etkileri aşağıdaki maddeler altında toplanabilir;

- Düşük yüzey kalitesi
- Yüksek takım aşınması
- İşlem başına zaman artışından kaynaklı maliyetler
- Tolerans dışı iş parçalarının maliyetleri
- Enerji maliyetlerinde artış
- Yüksek gürültü
- İş güvenliği riskleri

2.4. Tırlama Titreşimlerinin Tespiti

Tırlama titreşimleri Tespiti ve sebebinin anlaşılması oldukça güç olduğundan, tırlamanın engellenmesi ciddi zaman ve maliyet gerektirebilir. Tırlama titreşiminden kaçınmanın ilk adımı ise tırlamanın hangi koşullar altında meydana gelebileceğinin saptanmasıdır. Tırlama titreşimi saptandıktan sonra etkileri anlaşılabilir ve bu etkiler ortadan kaldırılarak tırlamanın meydana gelmesinden kaçınılabilir. Bu duruma bağlı olarak ilk olarak kesici takım tezgahı durumun izlenmesi gerekmektedir.

Freze operasyonlarında belirli bir takım iş parçasına göre hareket ederek istenilen geometri doğrultusunda talaş kaldırır. Bu operasyonlarda takımın hareketi ve kesici takım tezgahının karakteristiklerine göre tırlama oluşabilmektedir. Tırlama, talaşlı imalat operasyonlarında kesim sırasında ortaya çıkan bir çeşit titreşim türü olmakla birlikte, sürekli olarak etki gösteren periyodik olmayan kuvvetler sonucunda oluşmaktadır. Tırlama problemleri, tırlamanın tespiti ve kontrolü üzerine, Altıntaş ve Weck, Quintana ve Ciurana tarafından bazı temel çalışmalar yürütülmüştür [2,12]. Tırlamanın tespit ve kontrol edilmesi talaşlı imalat operasyonları açısından büyük

önem taşımaya rağmen endüstriyel kullanıcılar tarafından tırlamanın tespit edilmesi zorlu bir süreçtir [13].

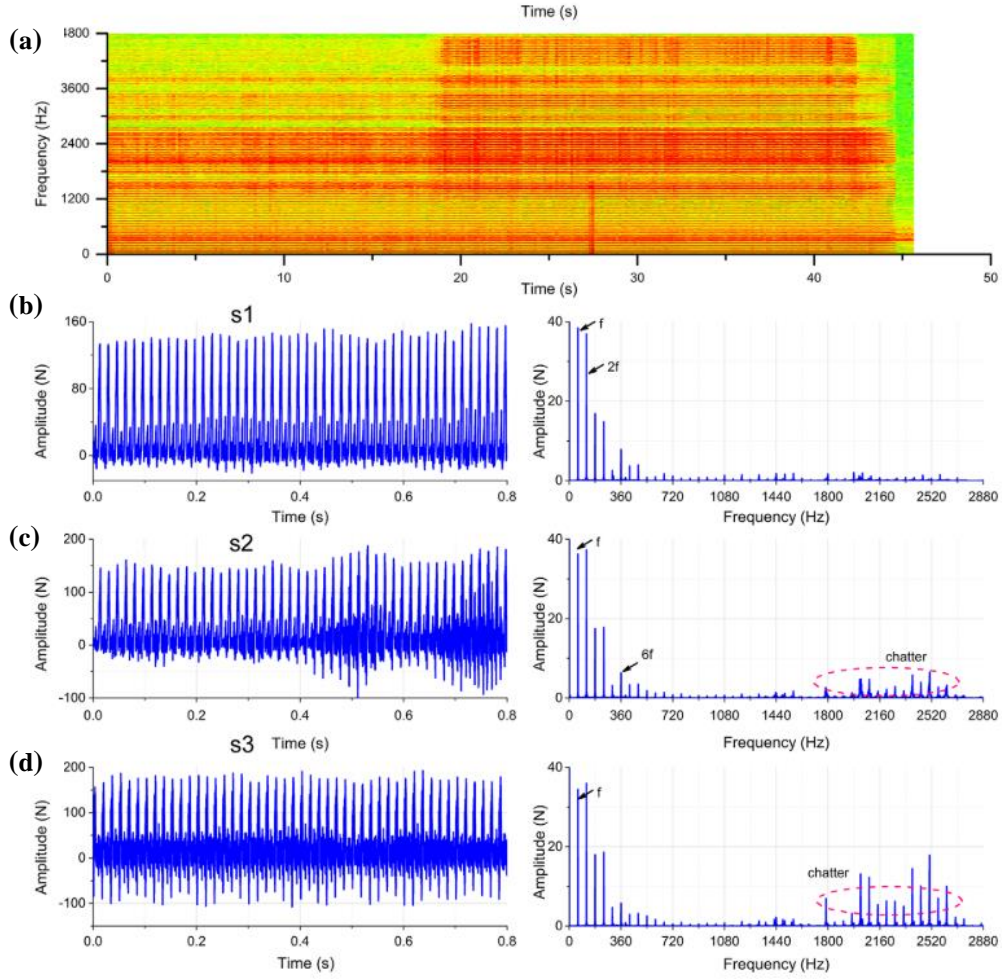
Literatürde, kesim anındaki sistemin durumunu öğrenmek için çeşitli sensörler ve elde edilen sinyal verileri kullanılmıştır. Yer değiştirme sinyali, ivme sinyali, kuvvet sinyali, akustik emisyonlar ve iş mili akımı bu sinyallere örnek olarak verilebilir. Genel yaklaşım, aynı takım durumu izleme uygulamalarında olduğu gibi kesim anındaki kuvvet ve ivme sinyalleri sensörler yardımıyla toplanım işlendikten sonra tırlamanın analizini gerçekleştirmektir [13].

Tırlamayı tespit etmek ve tanımlamak üzere birçok doğru analitik ve sayısal yöntem geliştirilmiştir [4, 7 - 9, 10, - 12]. Smith ve Tlustý tarafından sunulan yöntemde frezelemede, tırlama titreşimlerin zaman alanlı simülasyonları ile stabilite lobları oluşturulmaktadır [7]. Altıntaş ve Budak en başarılı analitik yöntemlerden birini geliştirmişlerdir. Stabilite loblarını tahmin etmek için frezeleme işlemindeki dinamik katsayılarından yararlanmışlardır [4]. Tornalama işlemlerine ilişkin analitik yöntemlerin çoğu ise, Siddhpura ve Paurobally tarafından geliştirilmiştir [13]. Ayrıca, gerek torna gerekse freze işlemlerinde benzer yöntemler Quintana ve Ciurana tarafından derlenerek yayınlanmıştır [2].

Tırlama titreşimini algılamak amacıyla farklı algılayıcılardan toplanan veriler, takım durumunu izleme süreçlerinde olduğu gibi zaman serisi şeklinde analog sinyallerdir. Tırlama titreşimini tespit etmek amacıyla tercih edilen en popüler izleme yöntemlerinden biri, mikrofon kullanılarak akustik emisyon sinyali toplamaktır. Bu amaçla, birçok araştırmacı tarafından ivmeölçerlerin yanında akustik emisyon verisi toplanarak da tırlama titreşimini tahmin etmek üzerine akademik çalışmalar yürütülmektedir. Delio vd. tırlama titreşimini gözlemlemek amacıyla ivmeölçer, deplasman transdüser ve akustik emisyon algılayıcısı kullanmışlardır. Burada yürütülen araştırmada algılayıcı tiplerinin performansları karşılaştırılmıştır. Çalışmalarının sonucu akustik emisyon sinyallerinin tırlama titreşimini tespit etmekte oldukça başarılı olduğunu gözlemlemişlerdir [14]. Altıntaş ve Chan tarafından yürütülen bir başka çalışmada, tırlama titreşimini tespit etmek amacıyla zaman-serisi şeklinde toplanan akustik emisyon sinyallerini spektrogramlara dönüştürmüşlerdir. Elde ettikleri spektrogramlardaki belirli frekans aralığında maksimum genlikleri izleyerek tırlama titreşimini tespit etmeye çalışmışlardır [15]. Schmitz vd. tırlama titreşimini tahmin eden bir indikatör geliştirmişlerdir. Geliştirdikleri indikatör

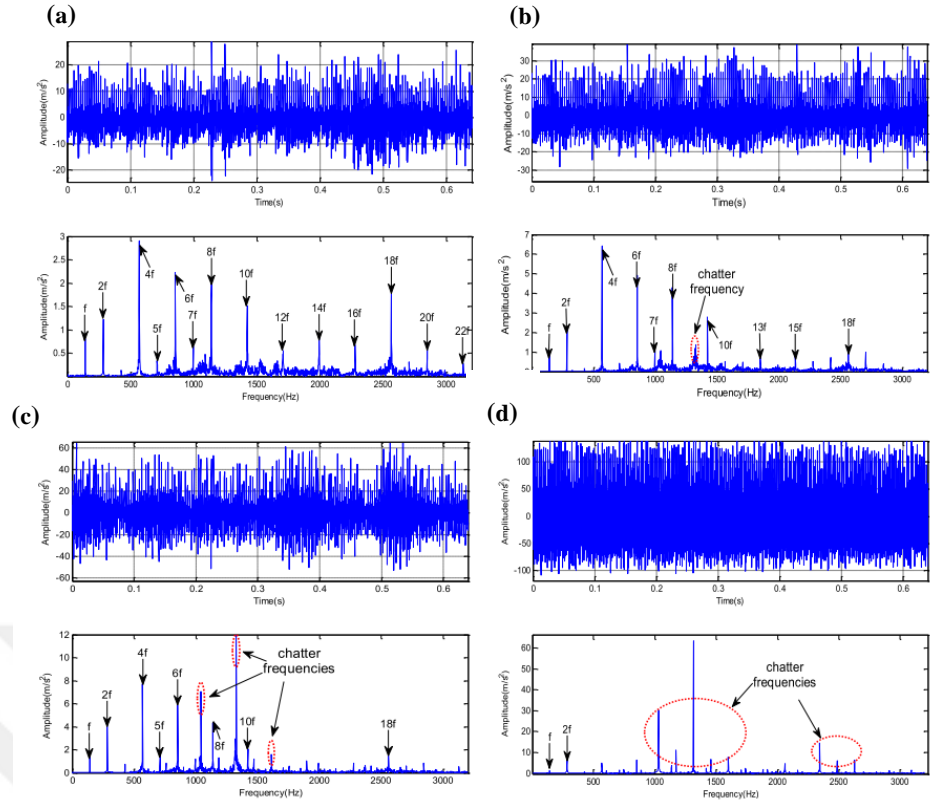
sayesinde, iş milinin her bir dönüşünde elde edilen akustik emisyon sinyallerindeki istatistiksel farklılıklar analiz edilmiştir ve bu farkların tırlama titreşimlerinin meydana gelmesi ile doğrudan ilgili olduğunu görmüşlerdir [16].

Frezeleme işlemleri sırasında tırlama titreşimi meydana geldiği zaman, zaman serisi olarak doğrusal olmayan (*non-stationary*) akustik, titreşim ve kesme kuvveti sinyalleri toplanır. Doğrusal olmayan sinyaller üzerinde daha iyi çalışabilmek için genellikle zaman-serisi şeklinde toplanan veriler üzerinde FFT dönüşümü uygulanarak veri türü frekans alanına dönüştürülür. Zhang vd. tarafından tırlama titreşimi olayını tanımlamak için enerji entropisine dayalı özgün bir yaklaşım geliştirilmiştir. Burada, durağan sinyallerden (*stationary signal*) oluşan kararlı durumda, Şekil 2.8’de gösterildiği gibi iş milinin dönme frekansının veriler üzerinde baskın olduğu gözlemlenmiştir. Fakat elde edilen verilerde durağan olmayan sinyallerin belirginleşmesi ile birlikte tırlama titreşiminin meydana geldiği gösterilmiştir [17].



Şekil 2.8: Deneysel kesime ait spektrogram (a) Durağan (b) ve durağan olmayan durumlar (c,d) [17]

Bir başka çalışmada ise tırlama titreşimini tespit edebilmek amacıyla ivmeölçer kullanılarak zaman-serisi şeklinde veriler toplanmıştır. Kararlı kesim (*stable cutting*) durumunda gözlenen baskın frekanslar, Şekil 2.9'da da görüldüğü gibi tırlama titreşiminden kaynaklı frekanslara yerini bırakmıştır. Başka bir ifadeyle, baskın frekanslar analiz edilerek tırlama titreşiminin oluşumu tespit edilmeye çalışılmıştır [18].



Şekil 2.9: Zaman serisi ve frekans alanında titreşim sinyalleri (a) kararlı durum (kesme derinliği 1 mm), (b) kararsız durum (kesme derinliği 2 mm), (c) kararsız durum (kesme derinliği 3 mm) [18]

Diğer taraftan, klasikleşmiş ve gözleme dayalı bu yönteme ek olarak Altıntaş ve Budak tarafından uzun süren araştırmalar sonucunda, bir freze işleminde dengeli kesimin sınırlarını belirlemeyi sağlayan teorik bir yöntem geliştirilmiştir. Bu yöntem genel olarak kesme derinliği (mm) ve iş mili hızını (dv/dk) eksenlerinde barındıran, buna ek olarak dengeli kesim bölgelerini bu eksenleri referans alarak gösteren bir kararlılık diyagramdır [9]. Soliman ve İsmail, bu yöntemin eksik yönlerinden en önemlisinin kararlılık eşitliklerinin proses parametrelerine karşı hassasiyeti olduğunu vurgulamışlardır. Teorik yöntemlerin barındırdığı bu hassasiyetten dolayı, geçmişte bu yöntemlere alternatif oluşturması amacıyla işlem sırasında toplanan verilerin incelenmesine bağlı tırlama algılama yöntemleri geliştirilmiştir [19].

Titreşim verileri kullanarak tırlama titreşiminin algılanmasında izlenecek bir diğer yol ise, zamana bağlı titreşim verisinin tamamını kullanmak yerine yalnızca sinyal özniteliklerini kullanmaktır. Analog verinin tamamının yerine sinyalin içerdiği önemli bilgileri ifade eden öznitelik kullanımı, tırlama titreşiminin algılanmasında


algoritmaların kullanımını yaygınlaştırmıştır. Bunun başlıca sebebi ise rassal değişkenlerin, verilerin tamamına oranla çok daha az hafızaya ihtiyaç duyması ve dolayısıyla daha yüksek hesaplama hızlarına imkan vermesidir. Bu durum göz önüne alınarak, sinyal özniteliklerinin tırlama titreşimini algılamak amacıyla geliştirilen sistemlerde kullanımına örnekler mevcuttur. Samanta vd., zamana bağlı titreşim verilerine STFT uygulayarak elde ettikleri sinyal değişkenlerini analiz etmiş ve tırlamanın algılanması için bu verilerden yararlanmışlardır [20]. Freze işlemi doğası gereği torna işleminden daha karmaşık dinamik özelliklere sahiptir. Bu nedenle freze işleminde ortaya çıkan tırlama, torna işlemine göre daha fazla değişkene bağlıdır. Bu durum freze işlemlerinde AI kullanımını daha kritik hale getirmektedir. Kuljanic vd. tarafından takım tezgahına bağladıkları dinamometreler ve ivmeölçerlerden veriler toplanmış bu verilerden ortalama değer, standart sapma ve çarpıklık gibi sinyal özniteliklerini elde etmişlerdir. Bu özellikleri bir tırlama algılama algoritmasına girdi olarak kullanmışlar ve tutarlı sonuçlar elde etmişlerdir [21]. Yao vd., bir freze işleminde oluşan tırlamayı bir SVM kullanarak gözlemlemiş ve yaklaşık tahmin modellerinde %95 oranında doğruluk değerine ulaşmışlardır [22]. Lamraoui vd., Al 7075 iş parçası üzerinde gerçekleştirdikleri bir freze işleminde, iki adet gizli katmana sahip DMLP yöntemi kullanarak tırlama titreşimini tespit etmek üzerine çalışmışlardır. Bu algoritmanın girdisi olarak ise RMS, varyans, çarpıklık, kurtosis ve maksimum değer sinyal özniteliklerinden yararlanmışlardır. Ayrıca farklı kombinasyonlar kullanarak elde ettikleri tahminleri birbirleriyle karşılaştırmışlardır [23]. DMLP modeli ve sinyal öznitelikleri kullanılarak tez kapsamında da bir tırlama algılama çalışması gerçekleştirilmiştir [24]. Bu model geliştirilen özgün yöntem ile karşılaştırmada kullanılmıştır. Chen ve Zhen, frezeleme işlemi esnasında topladıkları verilerden, dalga paketçisi ayırma (*Wavelet Packet Decomposition*) yöntemleri ile elde ettikleri sinyal özniteliklerini destek vektör makinası algoritmasına tanıtmış ve tırlama titreşimi ile ilgili tahmin modeli geliştirmişlerdir [25]. Chen vd., FFT kullanarak elde ettikleri frekansa bağlı verileri AI'ya entegre etmişlerdir. TI6AL4V alaşımın kullanıldığı bu frezeleme işleminde toplanan veriler ışığında, tırlamanın sinyal verilerinde gözlenebilen yüksek enerji seviyeleri ile bağlantısını gözler önüne sermişlerdir. Onlar, aynı teknikleri bu sefer mikro frezeleme işlemlerine uygulamışlardır. Sinyal özniteliklerini sıralamaya ve uygun olanlarını seçmelerini sağlayacak bir algoritma kullanarak AI'ya girdi olarak verilecek sinyal özniteliklerinin

içinden en doğrusunu seçmeyi ve dolayısıyla yüksek doğrulukta tırlama algılaması gerçekleştirmeyi amaçlamışlardır [26].

2.4.1. Stabilite Lobları

SLD, bir kesici takım operasyonunda gerçekleşmesi beklenen kararlı ve kararlı olmayan kesme parametresi aralıklarını (tırlama titreşimlerinin gerçekleşeceği muhtemel kesme parametresi aralıkları), kesme derinliği ve iş mili devrine bağlı olarak gösteren grafiklerdir. Kesici takım tezgahına ait dinamik özellikler ve kesici takım kuvvetleri teorilerini birleştirerek elde edilmiş bu grafikler sayesinde, işlem öncesinde tırlamanın meydana geleceği kesme parametreleri tahmin edilebilir ve bu sayede bu parametrelerden kullanılmadan kesim yapılabilir.

Bir frezeleme sisteminin SLD'sini belirlemek için, frezeleme işleminin dinamik davranışı modellenmelidir. Tornalama işlemine kıyasla, frezeleme süreçlerinin esnekliği, çok boyutlu takımlar ve kesme dişlerinin iş parçası ile kesintili teması, fiziksel modellemeyi daha karmaşık hale getirir. Tlusty, dik kesme için geliştirdiği temel stabilite teorisini, değiştirerek bu konudaki ilk çözümü geliştirmiştir. Kararlı bölgeyi belirleyen sınırlayıcı kesme derinliği değerini bulmak üzere iş parçası ve kesici takım arasındaki etkileşimi ortalama diş açısı yaklaşımı sistemin frekans yanıt fonksiyonunu (FRF) kullanmıştır [27].



Şekil 2.10: Tlustý tarafından geliştirilen SLD örneği [27]

Tlustý ve Smith, Weck ve Altıntaş tırlamanın olmadığı talaşlı imalat operasyonları için CAD/CAM programına elde edilen SLD'leri entegre etmiştir [28,29]. Zaman alanı çözümüyle elde edilen metotlar önemli sonuçlar vermektedir. Fakat, tırlamayı hızlı ve pratik bir şekilde tahmin etmek için SLD'leri analitik metotlar ile elde edilmesi tercih edilmektedir. Altıntaş ve Budak freze operasyonlarındaki stabilite sorununu çözmek için daha pratik bir metot geliştirmiştir. Zamana bağlı olarak değişen freze kuvvetlerine katsayılar halinde Fourier serisi açılımı uygulayarak freze için dinamik denge eşitlikleri elde edilip, elde edilen ifadenin özdeğerleri tırlama frekansının olduğu baskın titreşim modları seçilerek hesaplanmıştır [9]. Ortalama diş açısı yaklaşımı yerine seriler alınır ve ilk terim ortalama yerine hesaplamalarda kullanılır. Bu modele göre, bir diş (j) için anlık talaş kalınlığı şu şekilde ifade edilir;

$$h_j(\phi) = [\Delta x \sin \phi_j + \Delta y \cos \phi_j] \quad (2.3)$$

Olduğu durumda;

$$\Delta x = (x_c - x_c^0) - (x_w - x_w^0) \quad (2.4)$$

$$\Delta y = (y_c - y_c^0) - (y_w - y_w^0) \quad (2.5)$$

Eşitliklerinde x_c, y_c ve x_w, y_w kesici ucun ve iş parçasının x ve y yönlerindeki dinamik yer değiştirmeleridir. Kesici ucun bir dışındaki (j) kuvvetler ise aşağıdaki gibi isimlendirilir;

$$F_{t_j}(\phi) = K_t a h_j(\phi); F_{r_j}(\phi) = K_r F_{t_j}(\phi) \quad (2.6)$$

K_t (teğetsel kesme kuvveti) ve K_r (radyal kesme kuvveti) değerleri malzemeye özgü kesme kuvveti sabiti K_s ye bağlıdır. h_j değerinin ikame edilmesiyle birlikte, dinamik kesme kuvvetlerinin hesaplanması mümkün hale gelmektedir.

$$\begin{pmatrix} F_x & F_y \end{pmatrix} = \frac{1}{2} a K_t \begin{bmatrix} a_{xx} & a_{xy} & a_{yx} & a_{yy} \end{bmatrix} (\Delta x \ \Delta y) = \frac{1}{2} a K_t [A(t)] (\Delta(t)) \quad (2.7)$$

Burada F_x ve F_y değerleri tek bir dışın iş parçası ile teması neticesinde meydana gelen kuvvetleri ifade etmektedir. Freze işlemlerinde kullanılan kesici takımların çok büyük kısmının en az iki kesici uca sahip olduğu düşünüldüğünde, yapılan hesapların birden çok dişe sahip kesici takımlar içinde geçerliliği sağlanmalıdır. Buna istinaden her diş üzerinde meydana gelen kesme kuvvetleri bir A matrisinde toplanır. Bu A matrisi zamana göre değişen kesme kuvvetlerini toplu halde ifade eder. Aşağıda verildiği şekilde elde edilir;

$$\alpha_{xx} = \frac{1}{2} (\cos(2\phi) - 2K_r\phi + K_r \sin(2\phi)) \Big|_{\phi_{st}}^{\phi_{ex}} \quad (2.8)$$

$$\alpha_{xy} = \frac{1}{2} (-\sin(2\phi) - 2\phi + K_r \cos(2\phi)) \Big|_{\phi_{st}}^{\phi_{ex}} \quad (2.9)$$

$$\alpha_{yx} = \frac{1}{2} (-\sin(2\phi) + 2\phi + K_r \cos(2\phi)) \Big|_{\phi_{st}}^{\phi_{ex}} \quad (2.10)$$

$$\alpha_{yy} = \frac{1}{2} (-\cos(2\phi) - 2K_r\phi - K_r \sin(2\phi)) \Big|_{\phi_{st}}^{\phi_{ex}} \quad (2.11)$$

SLD elde edilmesi için kararlılık analizlerinin yapılmasındaki ilk adım frekansa bağlı olarak belirlenmiş titreşimlerin bulunması için frekans cevap fonksiyonlarının ve frekansa bağlı olarak değişen kuvvet değerlerinin birbirleriyle çarpılmasıdır. Bu yaklaşım daha önceki araştırmalarda da kullanılmıştır [9,30]. Bahsi geçen çarpma işleminin yapılmasının ardından elde edilen eşitliklerin çözülmesi ile Λ (kompleks eigen değerleri) elde edilir. Elde edilen bu değer frekans cevap fonksiyonlarından dolayı kompleks ve gerçek değerlere sahip olacaktır. Bu eşitlikler kullanılarak istenen değerlerin sınırlayıcı kesme derinliğini elde etmek olduğu düşünüldüğünde, Eşitlik 2.8, 2.9, 2.10 ve 2.11 çözümlerinden kompleks kısımlar atılarak sınırlayıcı kesme derinliği (limiting depth of cut) değerleri α_{lim} Eşitlik 2.12 şeklinde elde edilebilir.

$$\kappa = \frac{\Lambda_I}{\Lambda_R} = \frac{\sin \omega_c T}{1 - \cos \omega_c T} \quad (2.12)$$

İş mili hızı ve tırlama hesabında kullanılan eşitlik 2.13'ün kullanılmasıyla,

$$\omega_c T = \varepsilon + 2k\pi \quad \varepsilon = \pi - 2\psi \quad \psi = \tan^{-1} \kappa \quad n = \frac{60}{NT} \quad (2.13)$$

Burada ε değeri kesici takımın rotasyonu esnasında iki diş arasında meydana gelen faz farkı olarak isimlendirilirken, k değeri kesici takımın bir turu esnasında meydana gelen titreşimlerin tam sayısı olarak ifadesidir. n değeri ise iş mili devrini belirtmektedir. Sonuç olarak SLD grafiklerinde kullanılan sınırlayıcı kesme derinliği formülü farklı iş mili devirleri için eşitlik 2.14 şeklinde gösterilir;

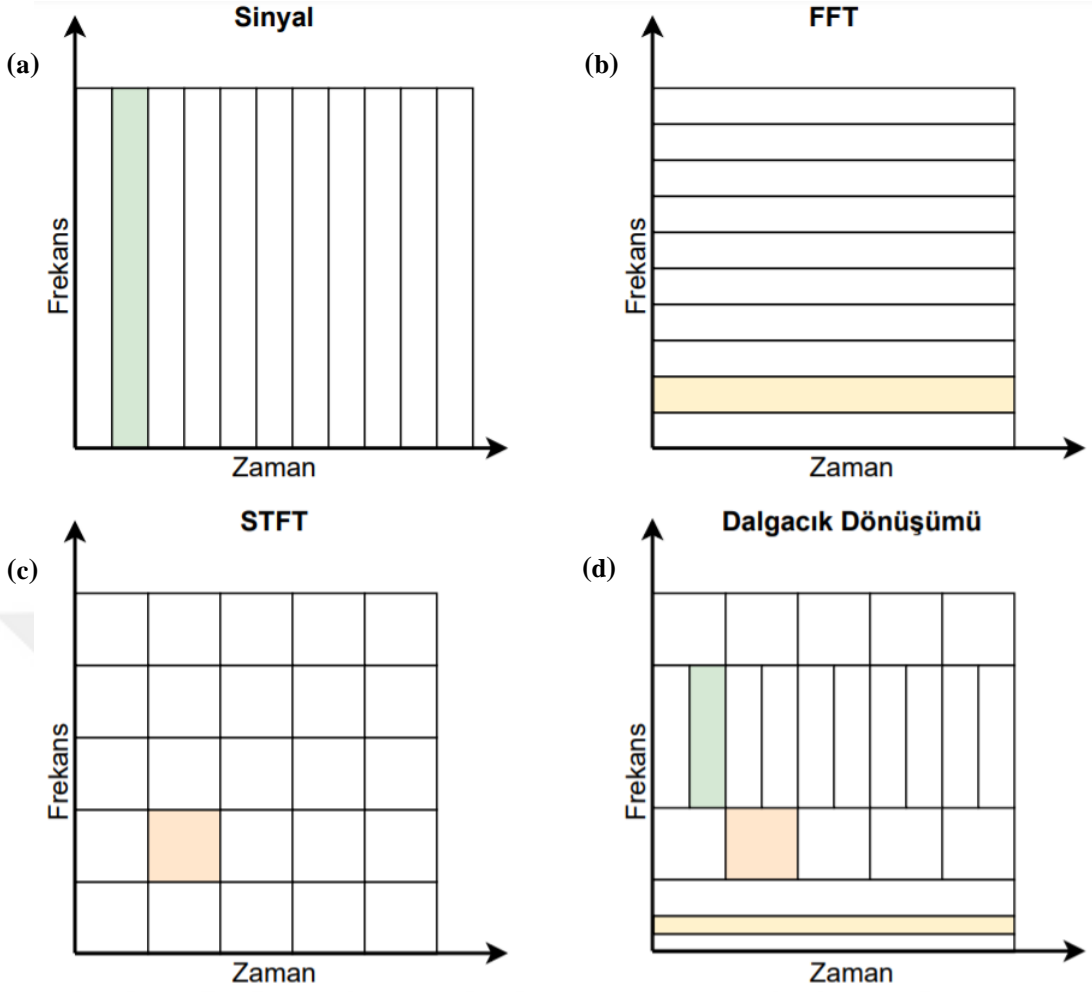
$$a_{lim} = -\frac{2\pi\Lambda_R}{NK_t} (1 + \kappa^2) \quad (2.14)$$

Bu eşitlikler dizisi kullanılarak farklı iş mili devirlerinde tırlama titreşimlerinin oluşması beklenen sınırlayıcı kesme derinlikleri hesaplanarak SLD grafikleri elde edilebilmektedir.

2.5. Dalgacık Dönüşümleri

Dalgacık (wavelet) dönüşümleri temel olarak, bir sinyalin hem zamana bağlı özelliklerini hem de düşük kayıpla frekansa bağlı olarak gösterilmesini sağlayan matematiksel dönüşüm işlemleridir. Dalgacık dönüşümleri birçok alanda kullanıma uygun sinyal işleme yöntemleridir. Dalgacık dönüşümlerinin, özellikle titreşim ve ses verilerinin işlendiği gibi yüksek güçte sinyal işleme teknikleri gerektiren uygulamalarda faydalı olmaktadır [31].

Dalgacık dönüşümlerini daha temel uygulamalardan olan kısa zamanlı Fourier dönüşümlerinden (Short Time Fourier Transform) ve hızlı Fourier dönüşümlerinden (Fast Fourier transform) ayıran temel fark, belirli bir zaman dilimindeki verinin, frekans ve zamana bağlı çözünürlüklerinin ayrı ayrı kontrol edilmesine olanak sağlamasıdır. Fourier dönüşümlerinde zaman çözünürlüğünden bahsedilemez. Kısa zamanlı Fourier dönüşümlerinde ise sinyal hem zaman hem frekansa bağlı olarak işlense dahi, çözünürlük değerinin değişimi mümkün olmamaktadır. Dalgacık dönüşümleri ihtiyaç duyulduğu takdirde ise farklı frekanslarda farklı çözünürlükler belirlenebilir. Şekil 2.11'de çözünürlükler görsel olarak ifade edilmiştir.



Şekil 2.11: Zamana bağlı sinyallerin işlemsiz halde (a), FFT (b), STFT (c) ve dalgacık dönüşümlerinden (d) sonra zamana ve frekansa göre çözünürlükleri

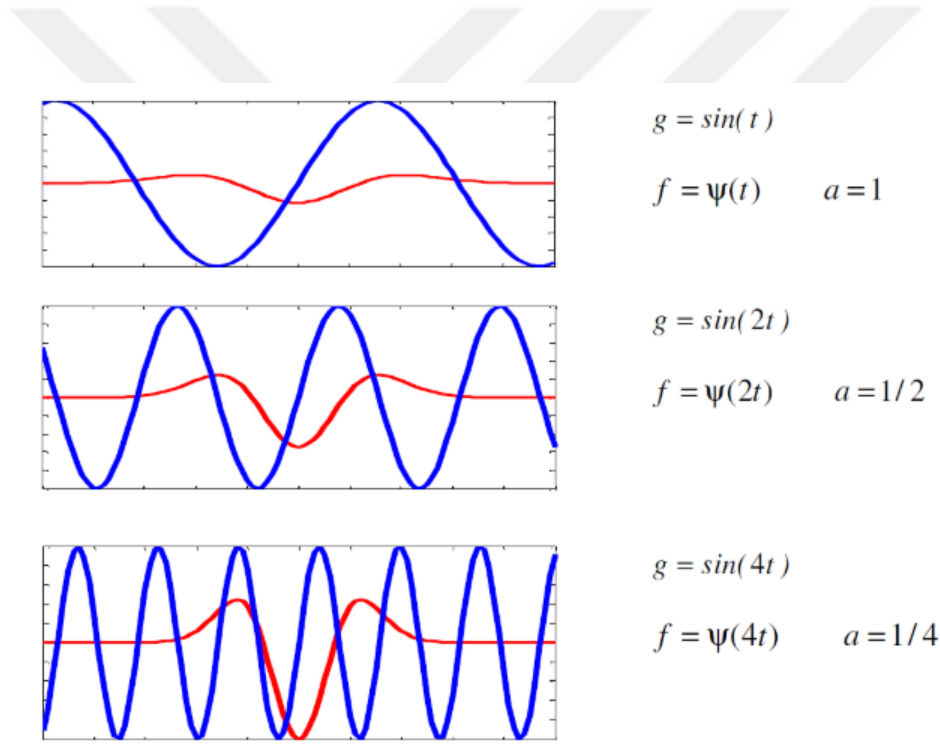
2.5.1. Sürekli dalgacık dönüşümleri (CWT)

CWT tek boyutlu zamana bağlı sinyalleri zaman ve ölçek (yarı-frekans) olacak şekilde iki boyutta elde etmeye yarayan yöntemdir. CWT işlemlerinde bir dizi ayrı ölçeğe sahip ve bu ölçeklere karşılık gelecek şekilde sinyal üzerinde gezdirilen ana dalgacıklar kullanılır. Ana dalgacık her bir ölçek ile çarpılıp elde edilen dalgacıklar sinyal üzerinde gezdirilir bu sayede sinyal dalgacık tarafından pencerelenmiş olur. Bu sayede sinyalin frekansa bağlı olan kısmı, sınırlı bant genişliğine sahip parçalara ayrılır ve bu parçalar en düşük düzeyde bilgi kaybı ile tekrar birleştirilerek sinyal iki boyutta ifade edilmiş olur. CWT işlemleri bir başka dalgacık dönüşüm metodu olan kesikli dalgacık dönüşümlerine (DWT) göre bazı avantajlara sahiptir. İlk olarak CWT işlemlerinde ölçek parametresi tam sayılar olmak zorunda değildir, bu ölçeklerin daha hassas belirlenmesi sayesinde sinyalin daha hassas işlenmesini sağlar [31]. Buna ek olarak CWT işlemlerinin, sağladıkları çoklu çözünürlük sayesinde takım durumu

izleme gibi doğrusallıktan uzak ve karmaşık problemlerde oldukça faydalı olduğu da bilinmektedir [32]. Ölçekleme parametresi ana dalgacığın büyüklüğünü değiştirir, yani zaman penceresinden bakılarak frekansa geçilirken kaç veri noktasının seçileceğini belirler. İşte bu yapı CWT işlemlerinde değişken çözünürlük elde edilmesini sağlar. CWT işlemlerini gösteren basitçe eşitlik 2.15 aşağıdaki şekilde belirtilmiştir [33];

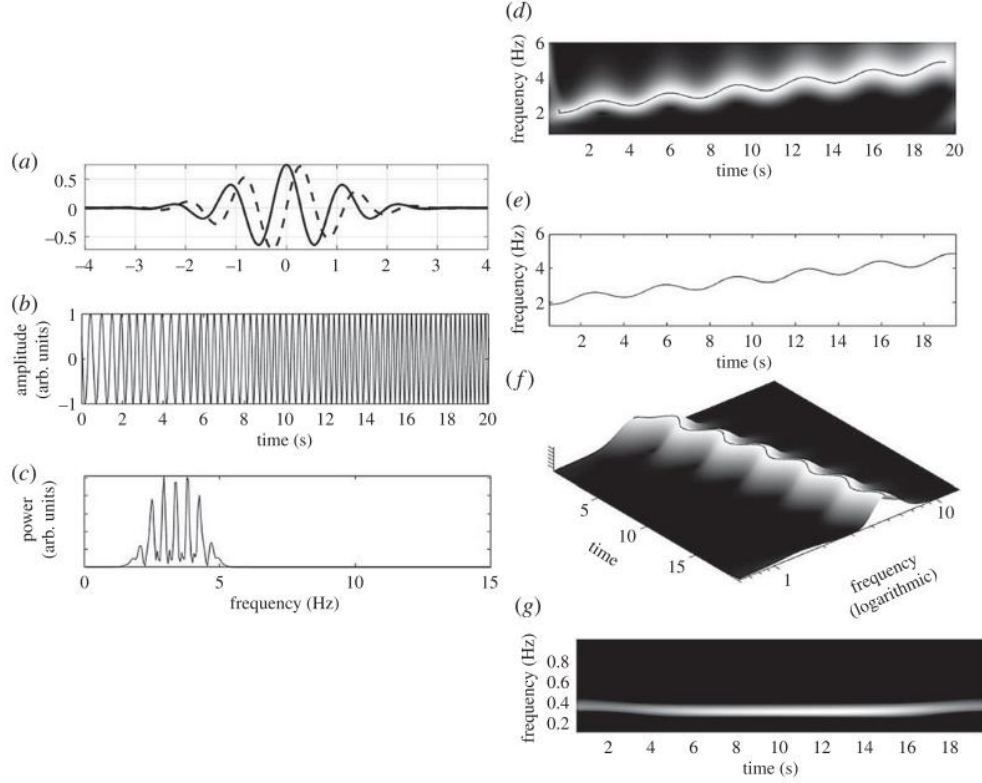
$$W_f(a, b) = \int_{-\infty}^{+\infty} F(x)\psi_{a,b}^*(x)dx \quad (2.15)$$

Burada a ve b sabitleri ölçeklendirme ve ilerleme ile ilgili ψ ana dalgacıkla ilgilidir. Ana dalgacık ve ölçek faktörü dalgacık dönüşümünün en önemli parametreleri olup, üzerinde çalışılacak probleme uygun olarak seçilmelidir. Ölçek parametresinin farklarının dalga üzerindeki etkisi aşağıdaki şekilde gösterilmektedir.



Şekil 2.12: Bir dalgacık üzerinde a parametresinin $1/2$ ve $1/4$ olarak seçimi [34]

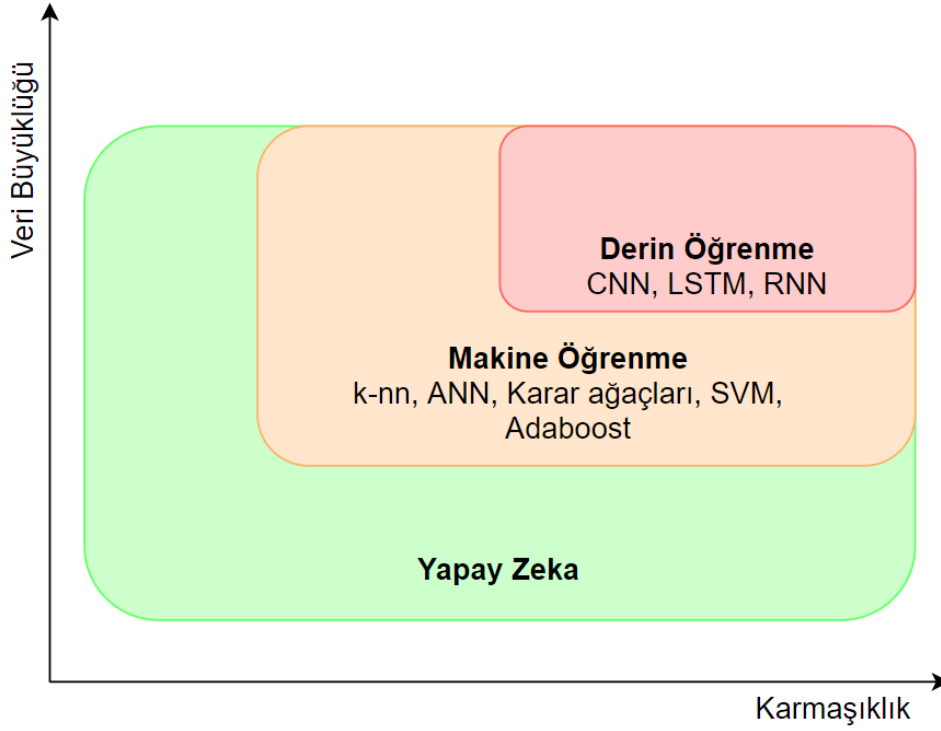
Ana dalgacık belirlenirken CWT uygulanacak problemin zaman-frekans karakteristiği önemlidir. Literatürde yer alan ve Tez kapsamında yapılan çalışmaya en yakın olan uygulamalar incelenmiş ve başlangıç noktası olarak morlet ana dalgacık kullanılmıştır. Bu seçimin en temel sebebi, morlet dalgacıklarının frekans ve zaman arasında dengeli bir çözünürlük sunmasıdır [35]. Bir morlet ana dalgacığının örnek bir sinyal üzerine uygulamasına ait sonuçlar Şekil 2.13'te gösterilmiştir.



Şekil 2.13: (a) Morlet dalgacık (reel kısım: düz çizgi. Sanal kısım: kesikli) kullanılarak elde edilen zamana göre değişen sinyal. (b) Değişken frekanslı test sinyali. (c) FFT güç spektrumu. (d) Sinyale uygulanan dalgacığın modu (siyahtan beyaza en düşükten en yüksek dalga büyüklüğüne doğru). (e) Dalgacığın sırt bölgesi. (f) Dalgacığın 3 boyutlu görüntüsü. (g) Dalgacığın 2 boyutlu görüntüsü [35]

2.6. Yapay Zeka Modelleri

AI, insan zekası süreçlerinin makineler, özellikle bilgisayar sistemleri tarafından simülasyonudur. AI'nın özel uygulamaları arasında uzman sistemler, doğal dil işleme, konuşma tanıma ve makine vizyonu yer alır. AI birçok farklı algoritmanın ortak adıdır, farklı tipler farklı karmaşıklıkta senaryolarda çalışmaktadır, temel olarak makine öğrenme ve derin öğrenme uygulamaları kapsar. Terimler arasındaki bu ilişki Şekil 2.14'te verilmiştir.



Şekil 2.14: AI, makine öğrenme ve derin öğrenmenin veri büyüklüğü ve karmaşıklığı ile olan ilişkisi [3]

Genel olarak, AI sistemleri, büyük miktarda etiketlenmiş eğitim verisi alarak, verileri korelasyonlar ve kalıplar çıkarmak üzere analiz edip bu kalıpları gelecekteki durumlar hakkında tahminlerde bulunmak için kullanarak çalışır. AI, işletmelere operasyonları hakkında daha önce farkında olmayabilecekleri içgörüler sunabilmesi ve bazı durumlarda görevleri insanlardan daha iyi yerine getirebilmesi nedeniyle önemlidir. Özellikle; tekrarlayan, detay odaklı görevler söz konusu olduğunda, AI araçları genellikle işleri hızlı ve nispeten az hatayla tamamlar.

2.6.1. Makine öğrenme

Makine öğrenme, AI'nın bir alt alanıdır. Eldeki belirli bir miktardaki veri ile probleme ait oluşturulan algoritma beslenerek eğitilir ve böylece makine öğrenme algoritması bu veriye dayanarak kendi mantığını oluşturur. Makine öğrenme algoritmaları 1) denetimli, 2) denetimsiz ve 3) pekiştirmeli öğrenme olmak üzere üçe ayrılır. Denetimli öğrenme (supervised learning) yöntemlerinde girdi değerleri ile istenen çıktı değerleri arasındaki ilişkiyi yansıtan bir algoritma oluşturulur. Eğitim verisi olarak hem girdiler hem de çıktılar yer alır. Yani etiketli veriler kullanılır. Tüm makine öğrenme

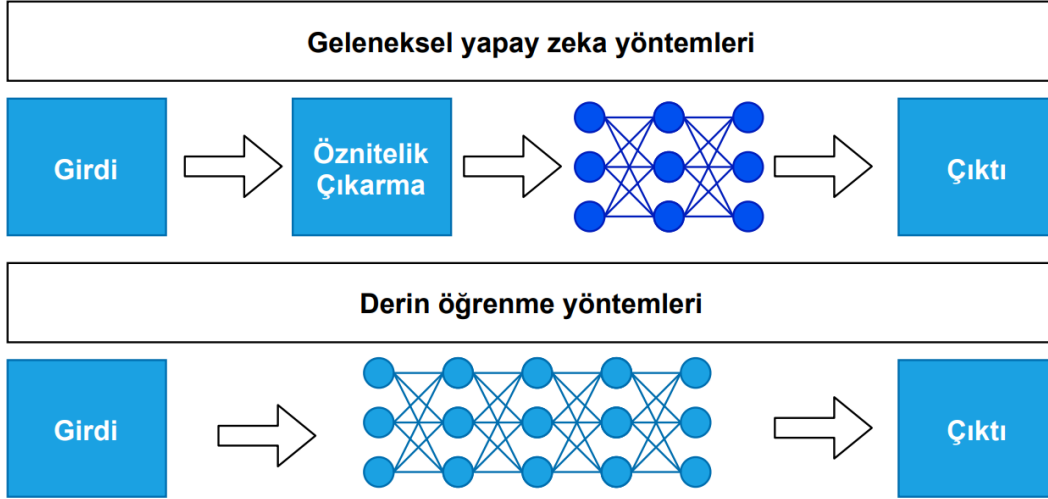
yöntemlerinin içinde en yaygın olanıdır. Denetimsiz öğrenme (unsupervised learning) yönteminde ise etiketlenmemiş (unlabelled) veri üzerinden bilinmeyen yapılar tahmin edilmeye çalışılır.

ML modelleri birçok takım durumu izleme ve talaşlı imalat performansı artırma çalışmasında kullanılmıştır. Farklı sensörlerden gelen verileri topluca değerlendirerek takım durumu izleme çalışmaları 1990'lara kadar dayanmaktadır [36]. Takip eden yıllarda ise bulanık ağlar, yapay sinir ağları ve probalistik yöntemler takım durumu izleme alanlarında sıklıkla kullanılmıştır [37]. Son yıllarda tezgah durumu izleme, takım durumu izleme ve hata algılama alanlarında özellikle yapay sinir ağları, bulanık ağlar ve SVM'lerden sıklıkla yararlanılmıştır [5,38].

Makine öğrenme yöntemleri her ne kadar kullanışlı olsa da birçok eksik yanı da içlerinde barındırmaktadırlar. Bu eksikler temelde ML modellerinin elde olan soruna entegrasyonu ve verilerin karmaşıklaşmasıyla bu modellerin eksik kalmasına dayanmaktadır. Bahsi geçen bu eksikler Nasir ve Sassani tarafından, literatürdeki tüm çalışmalar incelenerek derlenmiştir [39].


2.6.2. Derin öğrenme

Derin öğrenme modelleri temel olarak, ML modellerine göre daha karmaşıktır. ML modelleri içindeki sinir ağı yapıları en çok 2 katmana sahip olmaktadır [40]. Bu yapılara daha çok sayıda katman eklenmesi ile elde edilirler derin öğrenme modelleri geliştirilmiştir. Derin öğrenme modellerinin bu karmaşık ve gelişmiş yapıları, makine öğrenme modellerine göre daha iyi özellik mühendisliği (feature engineering) kapasitesidir [41,42]. Geleneksel AI ve makine öğrenme yöntemlerinde, modele girdi hazırlamak için yapılması gereken çalışmalar, derin öğrenme modellerinde model içerisinde gerçekleştirilmektedir. Serin vd. derin öğrenme modellerinin ML modellerinden olan bu temel farkını Şekil 2.15'teki gibi göstermişlerdir.



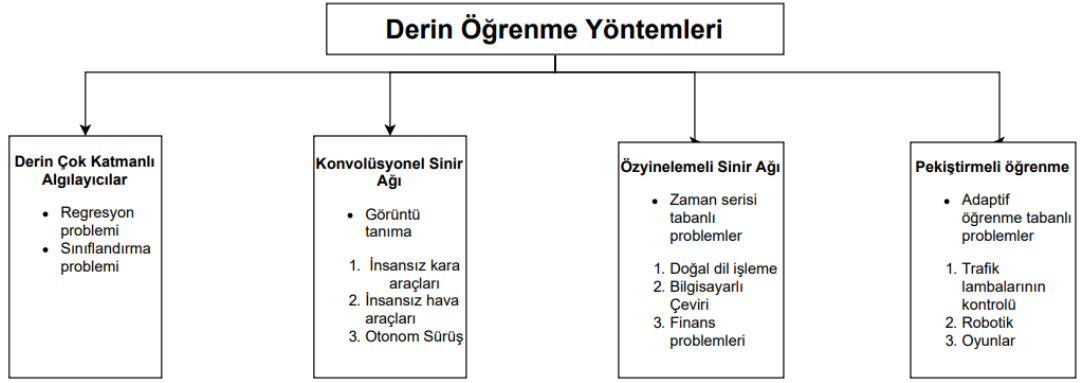
Şekil 2.15: Klasik AI ve derin öğrenme yöntemlerinin akış şemaları [43]

Makine öğrenme yöntemlerinin özellikle çok sayıda veri içeren uygulamalarda derin öğrenme modellerine göre daha düşük başarı gösterdiği bilinmektedir. AI modellerinin farklı sayıdaki verileri içeren problemlerde gösterdikleri başarıyı belirlemiştir.



Şekil 2.16: Veri büyüklüğü ve model performansı ilişkisi [43]

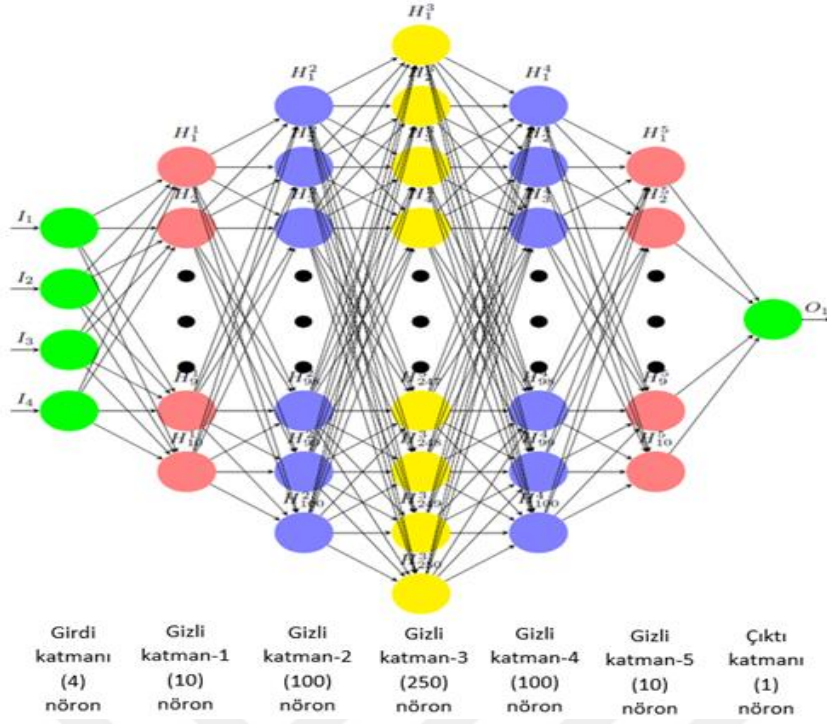
Derin öğrenme yöntemleri temel olarak sinir ağlarından meydana gelmektedir ancak farklı kullanım alanlarına göre mimarileri değişebilmektedir. Kullanım alanlarına göre DL yöntemleri Şekil 2.17’de verilmiştir.



Şekil 2.17: Derin öğrenme yöntemleri ve kullanım alanları [43]

2.7. Yapay Sinir Ağları

Yapay sinir ağları insan beynindeki nöronların çalışma prensibinden yola çıkılarak tasarlanmış bir istatistiksel öğrenme yöntemlerinden birisidir. Birçok matematiksel işlemin yapıldığı noktalar yapay nöronlar olarak adlandırılmaktadır. Yapay nöronlar ve sinir ağları, 1940'lı yılların başlarında Warren S. McCulloch ve Walter Pitts tarafından beynin matematiksel olarak modellenmesi üzerine yapılan çalışmalar neticesinde literatüre girmiştir [44,45]. Sinir ağlarının oluşturulabilmesi için Bir nöron kendisine bağlı diğer nöronlar ile iletişim kurabilmektedir. Tüm nöronların katmanlar halinde dizildiği ve birbirlerine bağlandığı bu yapılara ise yapay sinir ağları denmektedir. Her bir nöronun çıktısı o nörona bağlı olduğu nöronlardan gelen değerlerin doğrusal olmayan çeşitli fonksiyonlara sokulmasıyla elde edilir. YSA temel olarak girdi katmanları, çıktı katmanları ve arada yer alan bir dizi gizli katmandan oluşmaktadır. Şekil 2.18'de bir YSA ve katmanlar arasındaki ilişkiler gösterilmektedir. Şekildeki gibi bir YSA'nın işler halde olabilmesi için bir çok matematiksel model parametresinin ve fonksiyonun tanımlanması gereklidir. Güdelek yaptığı çalışmada yapay sinir ağlarının çalışma mekanizmasını detaylı şekilde ve anadilimizde açıklamıştır [46].



Şekil 2.18: Derin öğrenmede kullanılan sinir ağı mimarisi [47]

2.7.1. Konvolüsyonel Sinir Ağları (CNN)

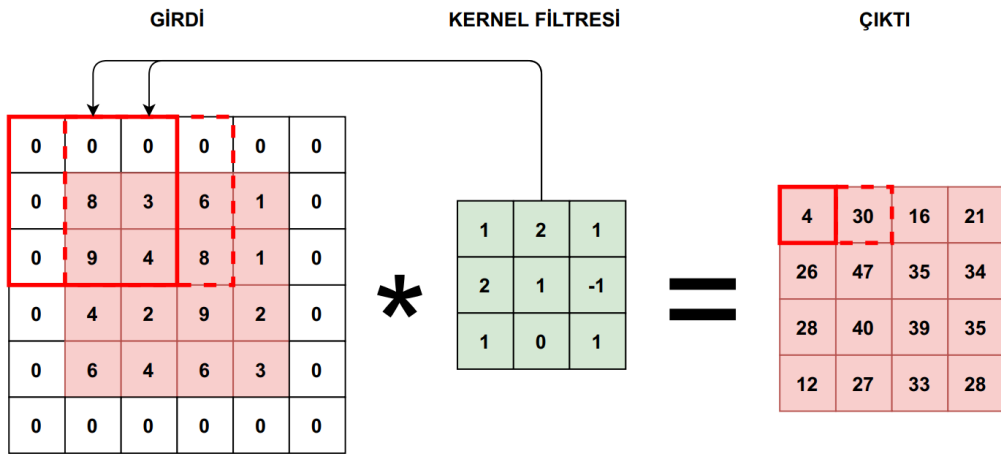
Tam bağlı yapay sinir ağlarının bir türü olan CNN ilk olarak [48] ve [49] çalışmalarında gösterilmiştir. CNN Lecun vd. yapmış olduğu çalışmada ise günümüzde en yaygın kullanılan haline gelmiştir [50]. CNN modelinin yaygın kullanım alanı bulması ise 2012 yılında gerçekleştirilen ImageNet yarışmasına dayanmaktadır. Bu yarışmada çok ciddi başarı gösteren yayın sayesinde modern olarak kullanılan CNN literatüre kazandırılmıştır [51]. CNN modellerini geleneksel tam bağlı yapay sinir ağlarından ayıran özellikleri ise belirli işlemleri gerçekleştirmek üzere tasarlanmış katmanlara sahip olmasıdır. Bunlar; konvolüsyon katmanı, havuz katmanı ve tam bağlı katmandır. Sıradan bir CNN mimarisinde katmanların sıralaması Şekil 2.19'da verilmiştir. Bu katmanlara ait detaylar takip eden bölümlerdedir.



Şekil 2.19: CNN mimarisinde yer alan katmanlar [43]

2.7.1.1. Konvolüsyon katmanı

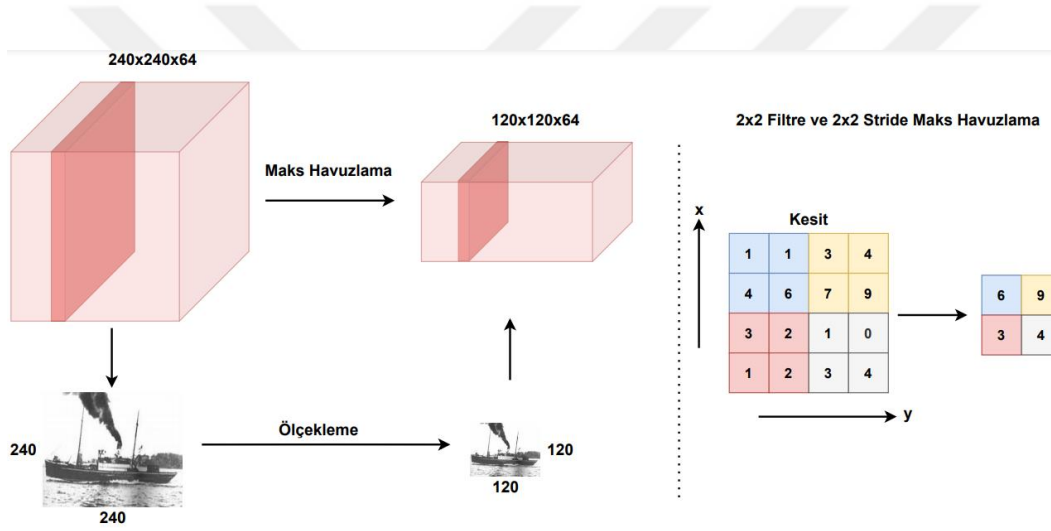
Konvolüsyon katmanı bir CNN modelinde yer alan en temel katmandır. Model mimarisinin ismi de yine bu katmanda gerçekleştirilen konvolüsyon işleminden gelmektedir. Konvolüsyon katmanlarında girdi matrisinin üzerinden bir filtrenin gezdirilmesi neticesinde çıktılar hesaplanır. Konvolüsyon katmanında girdinin içerdiği bilgi büyük ölçüde sıkıştırılarak bir sonraki katmana aktarılır. CNN modellerinin özellikle görüntü tanıma işlemlerinde kullanılmasının temel sebebi yine bu katmandaki operasyonun şeklidir. Filtre girdi üzerinde gezdirilirken her adımda filtrelerin kapladığı alanların ortak parçalara sahip olması, temelde resim üzerinde filtrelenen her parçanın birbirleriyle ortak piksellere yani bilgiye sahip olmasıdır. Şekil 2.20’de 6x6 boyutunda bir girdiye uygulanan filtreleme ve sonuçları verilmiştir. Bu örnekte stride parametresi 1 olarak, padding ise 0 olarak verilmiştir. Çıktı hesaplanırken 3x3 boyutunda olan filtre bir pixel kaydırılarak tüm girdi üzerinde dolaştırılmış, filtrenin pixellerinde yer alan sabitler ile piksellerin değerleri nokta çarpımı yapılarak çıktı hesaplanmıştır.



Şekil 2.20: Konvolüsyon katmanı operasyonları

2.7.1.2. Havuz katmanı

Havuz katmanları ekseriyetle konvolüsyon katmanlarının arasına yerleştirilir. Katmanlar boyunca ilerleyen bilginin daha değerli hale getirilerek küçültülmesi ve dolayısıyla öğrenilmesi gereken parametre sayısının azaltılması amacıyla uygulanır. Havuzlama katmanlarında yaygın olarak maksimum havuzlama yönteminden yararlanır. Burada katman içerisindeki değerler belirli parçalara ayrılır ve bu parçaların içerisinde en büyük değere sahip hücrenin değeri çıktının içine koyulur. Şekil 2.21’de verilen havuzlama örneğinde 2x2 stride kullanılmış ve 2x2 boyutundaki parçaların içindeki hücrelerden en büyük değere sahip olan maks havuzlama neticesinde çıktıda yer almıştır.



Şekil 2.21: Maks - Havuzlama

2.7.1.3. Tam bağlı katman

Bölüm 2.7’de anlatılan yapay sinir ağları ile birebir aynıdır. Bilgi yapay sinir ağları içerisinde matrisler halinde ilerler ancak tam bağlı katmana gelindiğinde vektör haline getirilir. Modelin tahmin işlemi tam bağlı katmanın sonunda gerçekleşmektedir.

2.8. Tırlama Titreşimlerinin Yapay Zeka Modelleri ile Tespiti

Tırlama titreşimlerinin oluşumu oldukça karmaşık olmakla birlikte doğaları gereği doğrusal olmayan birçok etkene bağlıdır. Titreşim verilerinden tırlama tespiti yapmak, uzun süren bir eğitim ve bir çok farklı disiplinden bilgiyi kullanmayı gerektirmektedir. Bu karmaşık problemde insanın üzerine düşen yükü azaltmak üzere AI modellerinden

sıkça yararlanılmaktadır. Bu bölümde tırlama titreşimlerinin AI modelleri ile tespitine dair yapılan çalışmalar, kullanılan AI modellerinin karmaşıklığına göre 3 madde halinde alınarak anlatılmıştır.

2.8.1. Makine öğrenme yöntemleri ile tırlama tespiti

Çevrimiçi tırlama tespiti için ML metodları kullanılırken bir veya daha fazla veri özelliği çıkarma (feature extraction) yöntemi, bir ön işleme adımı olarak kullanılmalıdır. Bu adım, sistem dinamikleri nedeniyle tırlamanın baskın olduğu kritik frekans bantlarının tanımlanmasında ve ortaya çıkarılmasında önemli bir rol oynar [32]. Öğrenme algoritmasının performansı için kritik olduklarından, makine öğrenimi modelleri daha gelişmiş hale geldikçe, buna paralel olarak veri özelliklerini çıkarma yöntemleri de geliştirilmiştir. Tırlama tespitinde ML modellerinin kullanılmasına dair ilk çalışmalar tornalama işlemine odaklandı. Rahman vd. tırlamayı ve takım aşınmasını izlemek için bir sinir ağı kullandı. Yüksek geçişli filtrelenmiş (high-pass filtered) sinyalden, beş farklı sinyal özelliği çıkarıldı ve bu özelliklerin değerleri, tırlamayı tahmin etmek için sinir ağına beslendi [33]. Lange ve Abu-Zahra, bir tornalama işleminde tırlama tespiti için bir multi-layer perceptron (MLP) kullandı. Sinyal özellikleri ultrasonik bir sensör ve ivmeölçer ile toplanan verilerden elde edildi. RMS (root mean square) özelliğine ait sayısal değerler dalgacık dönüşümleri, sinir ağlarına girdi olarak kullanıldı [34]. Kuljanic ve diğerleri, bir freze makinesinde dönen bir dinamometre, bir plaka dinamometresi ve çok sayıda ivmeölçer kullandı. Önce wavelet decomposition (WD) kullanıldı, ardından sinyalin ortalaması, standart sapması ve çarpıklığı gibi istatistiksel özellikler çıkarıldı. Bu iki tür veri çeşitli ML modellerine verilip ve sonuçlar karşılaştırılmıştır [18]. Tangjitsitcharoen ve diğerleri, bir freze operasyonundaki kesme kuvvetlerini izledi ve tırlamayı analiz etmek için topladıkları verilerin Daubechies dalgacıkları çıkarılarak ML modellerine beslenmiştir [35]. Yao ve diğerleri, bir Support Vector Machine (SVM) ve dalgacık paketi dönüşümü kullanarak delik çapı genişletme işlemi sırasında meydana gelen tırlamaları incelemesini gerçekleştirmiştir. Topladıkları SVM çıktılarını tekrar işleyerek son sonuçlara ulaştılar [16,19]. Liu ve diğerleri, sinyal işleme için dalgacık ayrıştırmasını kullanmışlardır (WD). Veri toplama için bir dinamometre ve bir ivme ölçer kullanıldı. Veri toplama ve dalgacık ayrıştırmasından sonra, ortalama ve varyans gibi sinyal özelliklerinin yanında kesme parametreleri SVM'e girdi vektörleri olarak verilmiştir [36]. Chen ve Zheng, frezeleme operasyonları üzerinde çalıştılar ve

dalgacık paketleri (Wavelet packages (WP)) aracılığıyla sinyal özelliklerini elde edilmiştir. Paketler bir SVM sınıflandırıcı için girdi olarak kullanılmıştır, bu SVM modelini kullanarak tırlama oluşumu gözlenen verileri sınıflandırdımışlardır. [21]. Chen ve diğerleri, tırlama tespiti için Ti6Al4V iş parçasının frezeleme işleminden elde edilen veriler 2 boyulu görseller haline getirdiler ve bu görüntü özelliklerini kullanarak SVM modeline verilecek girdileri elde ettiler. Mikro-frezeleme sırasında meydana gelen tırlama algılaması için bu SVM modelini kullandılar [22,37].

2.8.2. Derin öğrenme yöntemleri ile tırlama tespiti

Yukarıda özetlenen araştırmalara ek olarak, tırlama tespitinde bahsedilenlerden daha gelişmiş makine öğrenimi modelleri de uygulanmıştır. Lamraoui ve diğerleri, Alüminyum 7075 iş parçası üzerinde gerçekleştirilen bir freze işleminde çatırtı saptamaya odaklandı. Derin sinir ağının (Deep neural network) bir örneği olan ve içinde iki farklı gizli katmana sahip olan bir MLP (Multi-layer Perceptron) kullanarak, tırlamayı iki farklı durum altında sınıflandırmışlardır (normal ve tırlama durumları).

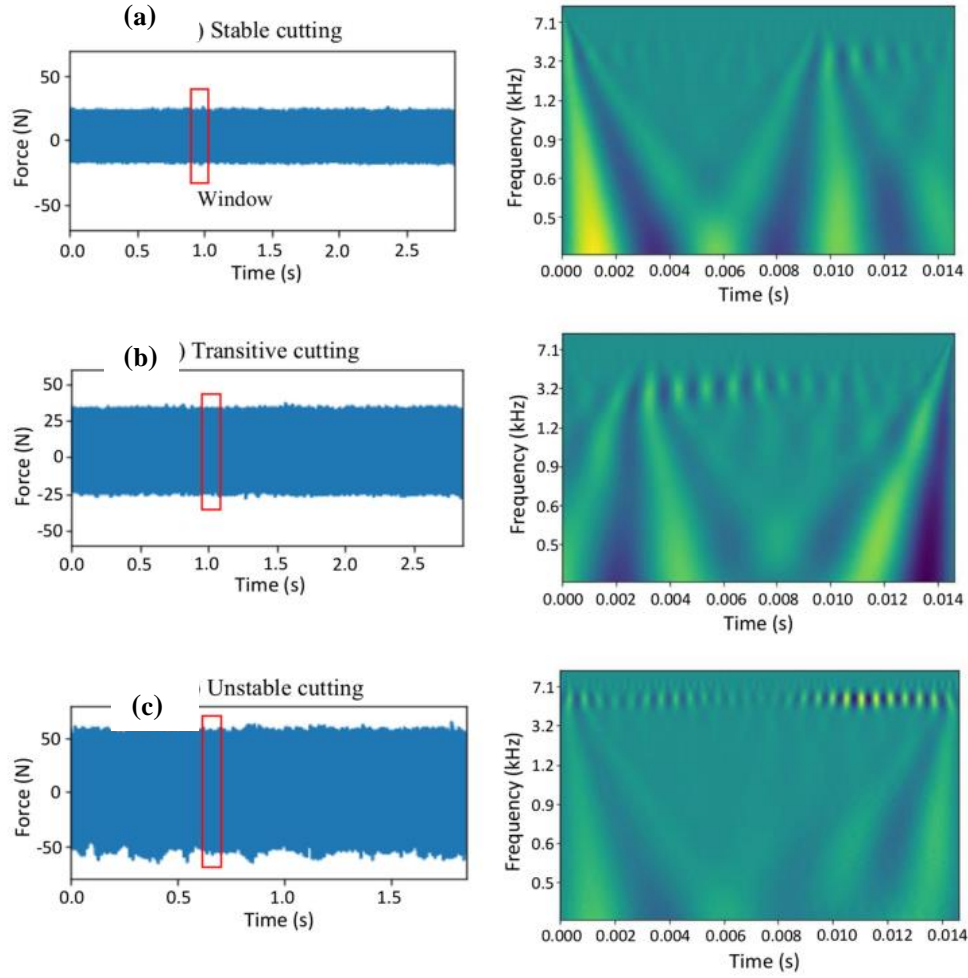
Sınıflandırma için sinyal özellikleri olarak varyans, basıklık, RMS, tepe faktörü, dürtü faktörü, çarpıklık, tepe değeri, açıklık faktörü ve şekil faktörü kullanılmış ve sonuçlar birbirleriyle karşılaştırılmıştır [23].

Cao ve diğerleri, tırlama algılama için çok sayıda istatistiksel özelliği girdi olarak kullandıkları ve derin mimari içeren bir self organising map (SOM) algoritması kullanmışlardır [52]. Oleaga ve diğerleri, bir random forest (RF) algoritması ile MLP'yi karşılaştırdı. Yapılan araştırmada bir derin öğrenme modeli olan MLP modelinin göreceli olarak daha basit bir ML metodu olan RF'e göre daha yüksek performans gösterdiğini ortaya koydu [53]. Ayrıca, Fu ve diğerleri, otomatik bir özellik çıkarıcı görevi gören bir deep belief network (DBF) tanıttı. Üç farklı makine durumu, boşta hareket, stabil kesme ve tırlama izlenmiştir. Otomatik ve manuel olarak sinyal özellikleri çıkarılmış ve karşılaştırılmıştır. Bu karşılaştırma sonucunda otomatik özellik çıkarma işlemleri sonuçlarının girdi olarak verildiği senaryolarda daha iyi sonuçlar elde edildiği görülmüştür [54].

2.8.3. Konvolüsyonel sinir ağları ile tırlama tespiti

Son zamanlarda, DL algoritmaları tırlama tespiti için sıklıkla kullanılmaktadır, özellikle konvolüsyonel sinir ağları (CNN) tırlama tanıma ve algılama işlemlerinde

kullanılmaya başlanmıştır. Fu vd. girdiler olarak dalgacıklarla birlikte bir CNN (derin konvolüsyonel sinir ağları) algoritması kullanarak bir çevrimiçi kesim durumu izleme gerçekleştirdi. Altı farklı veri kümesi içerisinde üç farklı tırlama durumu etiketi kullandılar. CNN'in basit sinir ağları ve SVM'nin farklı yapılarını aynı veri seti için karşılaştırdılar. Sonuç olarak ise CNN modelinin diğer modellere kıyasla daha yüksek başarı ile tahmin yaptığını gösterdiler [54]. Tran ve diğerleri, frezelemede tırlama tespiti için CWT'nin görüntü özelliklerini kullanan bir CNN algoritması önermişlerdir. Bir önce belirtilen çalışmada olduğu gibi dikkat çekici tırlama algılama doğruluğu elde edilmiştir [55]. Yine bu çalışmada kesim esnasında meydana gelen tırlama titreşimlerinin doğrudan dalgacık dönüşümleri üzerinde de kendini gösterdiğinin altı çizilmiştir. Kesme kuvveti değerlerinin stabil durumdan tırlamaya geçişinde dalgacıkların değişimi Şekil 2.22'de verilmiştir. Zu ve diğerleri, CNN modeli kullanarak tırlama tespiti için farklı bir strateji önermişlerdir. Kesme işleminden sonra iş parçasının fotoğraflarını çekmişlerdir. İş parçası üzerinde takımın geçtiği her bölgenin yüzeyleri yakın mesafeden fotoğraflanarak CNN modeline verilecek olan görüntüler elde edilmiştir. Yine kendileri tarafından tasarlanmış bir manyetik bakteri optimizasyon algoritması da CNN modelinin dizayn parametrelerini optimize etmek için kullanılmıştır. Elde edilen CNN modeli test edildiğinde % 98,8'lik kayda değer bir maksimum doğruluk elde edilmiştir [56].



Şekil 2.22: Stabil (a), geçiş (b) ve tırlama (c) durumlarına ait dalgacıklar [55]

Tüm bu araştırmaların derlenmesinin ardından yapılan tez çalışma aşağıdaki problemleri çözmek üzere geliştirilmiş bir yaklaşım içermektedir;

- Var olan modellerin kullandığı kesme verilerinin tüm kesimlerin verilerinin ortak bir havuz içerisinde toplanması ve bu havuzun karıştırılması yaklaşımıyla elde edilmektedir.
- Dalgacık dönüşümü gibi oldukça güçlü bir sinyal işleme aracı olan dalgacık dönüşümleri üzerinde tırlamanın tespiti gerçekleştirilmemiştir.
- İşleme ait kesme parametrelerinin tırlama tespitinde gelişmiş sinyal işleme araçları kullanılmamaktadır.
- Endüstriyel uygulaması kolay olan ivmeölçerler CNN modelleri üzerinde denenmemiştir.
- Tüm bu problemlerin çözümleri ve sonuçları bölüm 4.3 içerisinde detaylı olarak verilmiştir.

3. DENEYSEL YÖNTEM

Tez kapsamında yapılan deneysel çalışmalarda çekici testleri ve kesme deneyleri, orta büyüklükte bir dikey işleme merkezi olan DMG-MORI™ DMU 65 Monoblok üzerinde gerçekleştirilmiştir. Bu tezgah TOBB ETÜ İleri imalat teknolojileri laboratuvarında bulunmaktadır ve Şekil 3.1’de gösterilmektedir. 5 eksen kabiliyetine sahip bu tezgahlar özellikle yüksek hassasiyetin yanında karmaşık geometrilerin üretimini gerektiren uygulamalarda sıklıkla kullanılmaktadır.



Şekil 3.1: Deneyler kullanılan 5 eksen freze tezgahı

Tezgaha ait temel özellikler ise Çizelge 3.1’de verilmiştir.

Çizelge 3.1: Tezgah özellikleri.

X/Y/Z Hareketi (mm)	735/650/650
Çalışma Hacmi (dm ³)	268
İş Mili devri (devir/dak)	20000
Tork (Nm)	130
Güç (kW)	35

Tırlama titreşimlerinin gözlemleneceği veri setini hazırlamadan önce gerçekleştirmek gereken ilk adım tezgahın dinamik özelliklerinin elde edilmesidir. Bu özellikleri elde

etmek üzere tezgahın üzerinde çekiç testleri gerçekleştirilmiştir. Daha sonra çekiç testlerinden elde edilen bilgiler analiz edilerek, deneylerin yapılacağı kesme parametrelerine belirlemek üzere SLD'ler elde edilecektir. Bu işlemler devam eden bölümlerde detaylarıyla belirtilmiştir.

3.1. Takım Tezgahının Dinamik Özelliklerinin Elde Edilmesi

Bir sistemin dinamik analizinin yapılmasında, modal analiz yaklaşımı sıklıkla kullanılan ve kabul görmüş bir yöntemdir. Modal analiz yöntemi kullanılarak yapılan testler doğrultusunda sistemlerin yalnızca titreşim özelliklerinden faydalanılarak doğal frekansları, sönüm değerleri ve mod şekilleri gibi dinamik özellikleri belirlenebilmektedir. Modal analiz yönteminde; sistemi uyarıcı çekiç veya titreştiriciler, uyarıcılardan kaynaklanan titreşimleri ölçmeye yarayan ivmeölçerler, lazerli titreşim ölçüm cihazları veya fotogrametrik kameralar kullanılır. Modal analiz yönteminde sistemin çalışması gerekmediği için işlemler kolayca tekrarlanabilmektedir.

Tez kapsamındaki deneylerinde uygulanan modal analiz için çekiç testi yöntemi seçilmiştir. Çekiç testi bir modal çekiç ve bir ivmeölçer kullanılması ile gerçekleştirilir. Çekiç ile sisteme anlık girdi verilir ve bu anlık girdi, sistemin doğal frekanslarını tetikler. Sisteme bağlanan ivmeölçer yardımıyla, sistemdeki titreşim değerleri ve çekiğin ucundaki kuvvetölçer yardımıyla da kuvvet değerleri okunur. Bu değerler bilgisayar kontrollü bir veri toplama sistemine gönderilerek, genlik ve faz diyagramları elde edilir. Elde edilen genlik – faz grafiği incelenerek doğal frekans bölgeleri tespit edilir.

Çekiç testlerine başlamamın ilk adımı ise, deneylerde kullanılacak iş parçasının özelliklerinin belirlenmesidir. Tezgah üzerine yerleştirilen iş parçası, her ne kadar tezgahın dinamik özelliklerine ciddi bir etki yapmasa da kesici takımın belirlenmesi için önemlidir. Kesici takım, kesim esnasında iş parçası ile ilk teması yaşayan bölge olması sebebiyle dinamik davranışları belirlemede çok önemli rol oynar. Çekiç testleri de doğrudan kesici takımın üzerine bağlanan algılayıcılar ve darbe çekiçi kullanılarak yapılır. Bunlara istinaden bu çalışmalarda öncelikle iş parçası belirlenmiş ve buna uygun kesici takım seçilmiştir.

Tez kapsamındaki deneylerde iş parçası olarak, havacılık/uzay, savunma ve otomotiv gibi sanayilerde sıklıkla kullanılan Al 7075-T6 seçilmiştir. Bu alaşımın içeriği ve özellikleri Çizelge 3.2’de verilmiştir.

Çizelge 3.2: Al 7075-T6 malzeme özellikleri.

Alaşım İsmi	Aluminyum 7075-T6
İçerik	%5,5 Zn, %2,5Mg, %1,5 Cu, %0,3 Cr, Maks. 0,5 Fe, Maks. 0,4 Si, Maks. 0,3 Mn
Sertlik	150 HB
Yoğunluk	2,810 g/cm ³
Termal İletkenlik	130 W/mK
Young Modülü	7,20e+010 N/m ²
Uzama Yüzdesi	%0,11
Çekme Dayanımı	5,72e+008 N/m ²
Akma Dayanımı	5,03e+008 N/m ²
Kesme Dayanımı	3,31e+008 N/m ²
Erime Noktası	635 °C
Termal Genleşme Sabiti	25.200 µm/m-°C

Sonrasında seçilen iş parçası alaşımına uygun olarak 10mm çapında 3 dişli ve karbür kaplamalı bir kesici takım seçilmiştir. Bu takımın detaylı özellikleri ve geometrisi Çizelge 3.3’ de verilmiştir.

Çizelge 3.3: Deneylerde kullanılan kesici takım ucuna ait özellikler.

Çap (mm)	10
Uç Sayısı	3
Kaplama	Karbür
Küreme Açısı (derece)	6
Helis Açısı	30
Köşe Yarıçapı (mm)	1


3.1.1. Çekiç testi

Çekiç testlerinde ilk aşama olarak iş mili uygun konuma getirilmiş ve kesici takımın uç noktasına bir ivmeölçer tutturulmuştur. İvme ölçer kesim işleminin gerçekleştirileceği eksene paralel olarak kesici takımın ucuna bağlanmıştır. Modal çekiç, ivmeölçer ile aynı doğrultuda ve ivmeölçerin tam karşısında hizalanarak kesici takıma vurulmuştur. Şekil 3.2’de modal çekiç ve ivmeölçerin konumları gösterilmektedir. Test esnasında modal analiz için gerekli verilerin doğruluğunu arttırmak amacıyla 5 adet başarılı vuruşun ortalaması alınmıştır. Her vuruş sonrasında çekiçten alınan sinyalin durgun hale gelmesi beklenerek, yanlış veri toplanmasının önüne geçilmesi amaçlanmıştır.



Şekil 3.2: Çekiç testi esnasında çekiç ve ivmeölçerin yerleşimi

Çekiç ve ivmeölçerden veriler kullanılarak sistemin genlik – faz grafiği elde edilmiştir. Bu grafiklerden uygun noktalar seçilerek bu noktalara göre sistemin mod şekilleri ve doğal frekansları belirlenmiştir. Elde edilen bu frekanslar daha sonra SLD’lerin elde edilmesi üzere CUTPRO Machining Simulation uygulamasına aktarılmaktadır. Modal parametrelerinin çıkartılması ve bahsi geçen uygulamaya sokulmasına kadar izlenen adımlar Şekil 3.3’te gösterilmektedir.



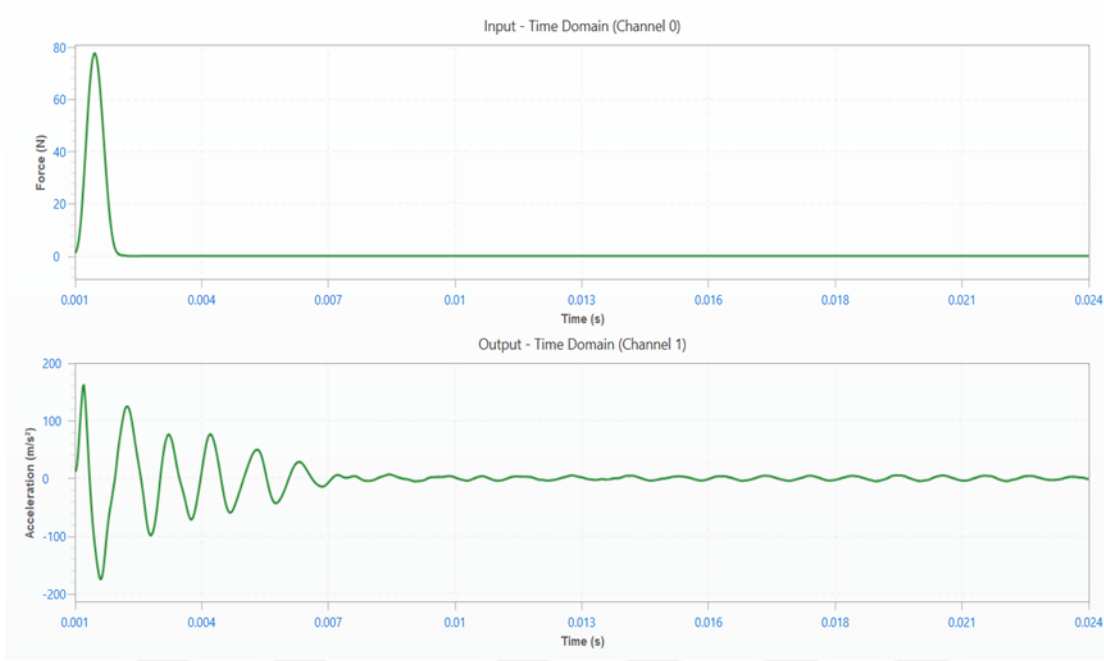
Şekil 3.3: Modal parametrelerin elde edilmesi [57]

Çekiç olarak PCB Piezotronics® 086C04 model bir modal çekiç kullanılmıştır. Kullanılan çekiğin teknik özellikleri Çizelge 3.4'te gösterilmektedir. National Instruments 9234 modülüne bağlanan ivmeölçer ve çekiçten alınan veriler, CUTPRO yazılımın Taptest modülü kullanılarak işlenmiştir.

Çizelge 3.4: Kullanılan çekiğin teknik özellikleri.

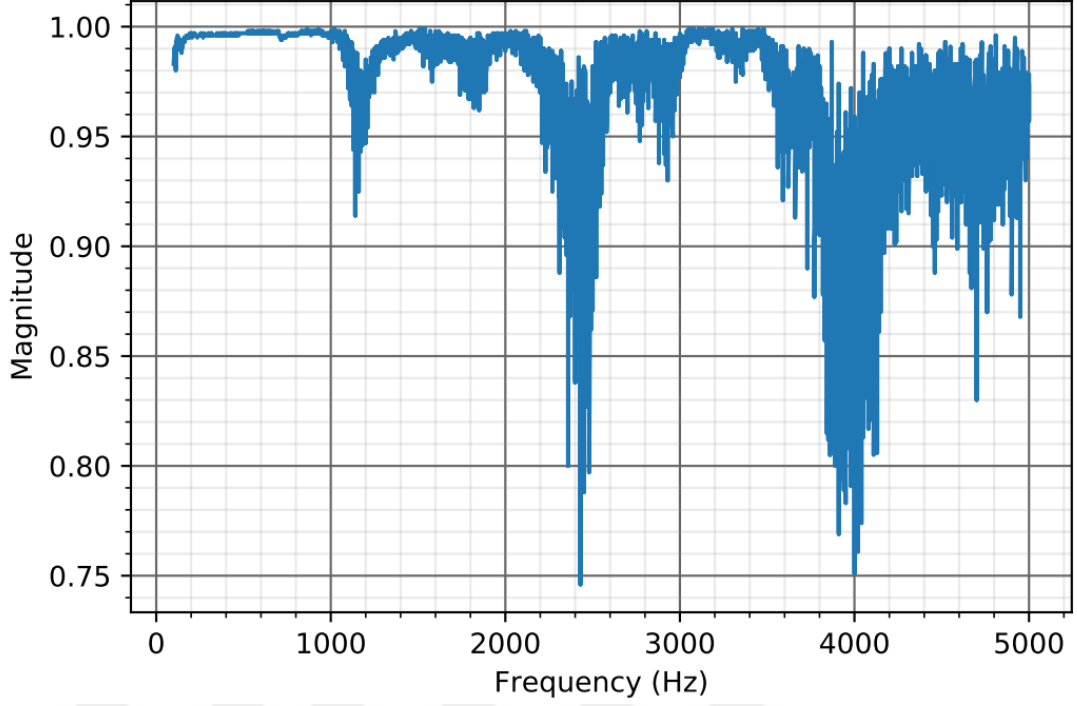
Hassasiyet \pm %15	1.1 mV/N
Ölçüm Aralığı	\pm 4448 N
Rezonans Frekansı	\geq 22 kHz
Uyarı Gerilimi	20-30 VDC
Çıkış Gerilimi	8-14 VDC
Çalışma Akımı	2-20 mA
Uç Malzemesi ve Sertliği	Plastik/Orta

Çekiç testi sırasında, ivmeölçer ve modal çekiçten toplanan veriler zamana bağlı olarak takip edilebilmektedir. Şekil 3.4'te gerçekleştirilen bir çekiç testinde yer alan 5 vuruşun ortalama vuruş ve yanıt değerleri görülebilmektedir. Şeklin yukarısında yer alan grafik modal çekiçi temsil ederken, aşağısında yer alan grafik ivmeölçeri temsil etmektedir.



Şekil 3.4: Çekiç testi neticesinde elde edilen eş zamanlı kuvvet(çekiç) ve ivme (ivmeölçer) verileri.

Bağdaşıklık grafikleri, yapılan ölçümlerin kalitelerinin doğrulanmasında ilk tercih edilen yöntemlerden biridir. Bu grafikler incelenerek, yapılan ölçümlerin ölçüm teknikleri açısından doğrulukları kontrol edilebilmektedir. Düzgün bir çekiç testinde girdi ve çıktı cihazlarından okunan değerlerin aynı şekilde doğrusal olması beklenmektedir. Çapraz spektrum grafikleri bağdaşıklık grafiklerinin elde edilmesinde kullanılır. Her ne kadar bu grafiklerin fiziki bir anlamı olmasa da bu grafikte bulunan tepe noktaları sistemin doğal frekans değerlerini göstermektedir. Yapılan çekiç testinde CUTPRO uygulamasının Taptest modülünün içerisinde üretilmiş olan grafikler kullanılmıştır. Şekil 3.5'te çekiç testi verilerinden elde edilen bağdaşıklık grafiği görülmektedir.



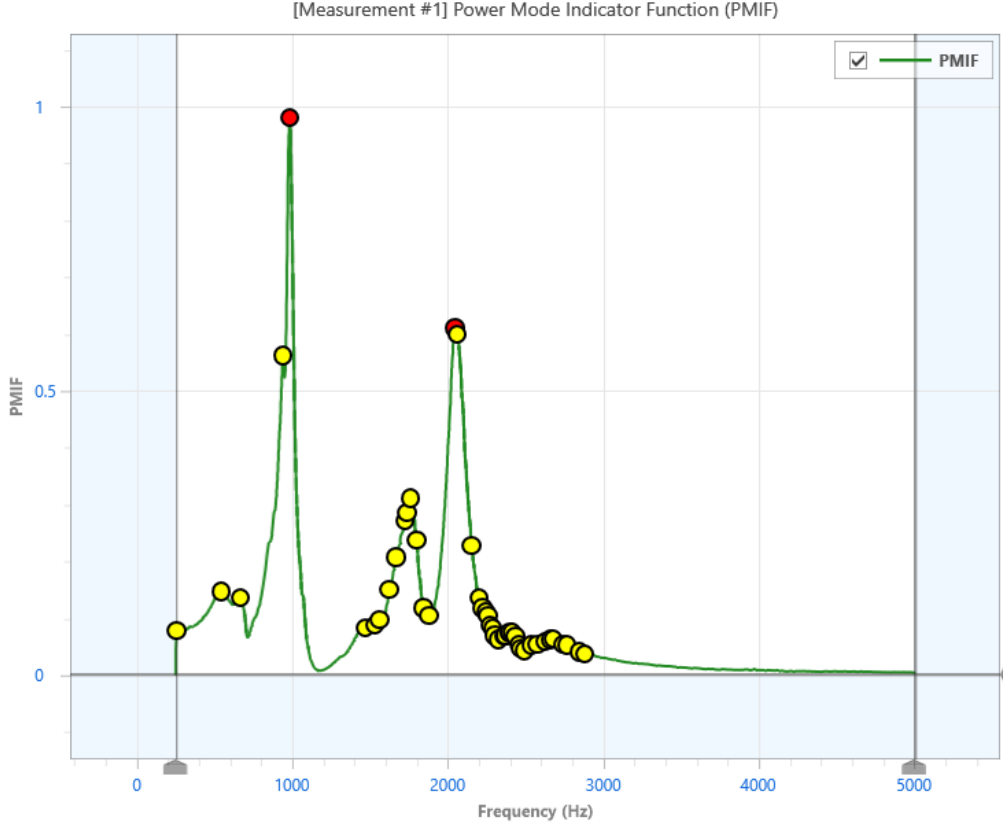
Şekil 3.5: Çekiç testi neticesinde elde edilen bağdaşıklık grafiği

Mükemmel şartlarda gerçekleştiği kabul edilen bir çekiç testinden elde edilecek bağdaşıklık grafiğinde, bağdaşıklık değerleri 1,0 (%100) olacaktır. Çoğu koşulda görülmesi beklenen değerler ise 0,8 ile 1,0 arasında olacaktır. 0,8'lik bir bağdaşıklık değeri ölçümün mükemmel teknikten %20 uzak olduğu anlamına gelmektedir. CUTPRO Taptest modülün kendi yönergesinde belirtildiği üzere 0,8 üzerinde bir bağdaşıklık değeri, ölçümün uygunluğu konusunda kabul edilebilir düzeyin içerisinde sayılmaktadır. İvmeölçerinde test esnasında sisteme uygun şekilde bağlanamaması, her ne kadar 5 adet vuruş ortalaması alınsa dahi modal çekiçin doğru açıda vurulmaması ve ivmeölçer-modal çekiç doğrultusunun doğru ayarlanamaması bağdaşıklık değerini düşüren başlıca etmenler olarak kabul edilmektedir.

Test sonucu elde edilen bağdaşıklık grafiği incelendiğinde 2400 Hz dolaylarında 0,8 ve 2200 dolaylarında yaklaşık 1,0 olan bağdaşıklık değerleri elde edilmiştir. Baskın doğal frekans değerleri göz önüne alındığında, çapraz spektrum grafiğinde yer alan tepe noktalarına karşılık gelen tüm frekanslarda test yüksek doğruluğa sahiptir. İlgili alanı olan 2500 Hz dolaylarına kadar kabul edilebilir düzeyde bir bağdaşıklık değeri vardır.

3.1.2. Modal analiz

Çekiç testinin tamamlanmasının ardından sistemin dinamik özelliklerinin belirlenmesi ve kesim simülasyon programında kullanılacak olan verilerin sağlanması amacıyla modal analiz safhasına geçilmiştir. Bu safhada Şekil 3.6'da görülen güç spektrumlarından yararlanılmaktadır.



Şekil 3.6: Modal analiz esnasında seçilen doğal frekanslar


Şekil 3.6'da görülen grafik temel olarak sistemin her modunun esnekliğine ve doğal frekanslarına dair bilgi vermektedir. Sistemin birim kuvvet tarafından belirli bir frekansta titreştirildiğinde bu titreşimin büyüklüğünü ifade etmektedir. Grafik üzerinde bulunan noktalar çekiç testinden alınan veriler doğrultusunda CUTPRO modal analysis modülünün belirlediği tepe noktalarını sembolize etmektedir. Bağdaşıklık matrisleri göz önüne alındığında, ölçümün doğruluğunun yüksek olduğu 2400 Hz ve altının değerlendirilmesi uygundur. Bunun yanında mod noktaları seçilirken sistemi iyi şekilde ifade etmeyi sağlayacak minimum sayıda nokta belirlenir. Belirlenen noktalara oturtulan bir doğru neticesinde sistemin dinamik özellikleri belirlenmiş olur. Özellikle dahil edilmesi gereken noktalar ise


Şekil 3.6’da görülebilen tepe noktalarıdır. Noktaların belirlenmesini takip eden aşamada sistemin sertlik ve sönüm değerleri belirlenir. Çizelge 3.5’e sistem içerisinde seçilmiş noktalara karşılık gelen dinamik özellikler (modal parametreler) gösterilmektedir.

Çizelge 3.5: Sisteme ait doğal frekans ve modal parametreler.

Mod No	Frekans (Hz)	Sönümlenme Oranı (%)	Modal Sertlik (N/m)	Modal Kütle (kg)
1	983.28	3,76	1,79e07	0,469
2	2034.26	3,64	2,04e07	0,125

Doğal frekansların tayini için titreşimin transfer fonksiyonun reel ve imajiner kısımlarından da yararlanılabilmektedir. Şekil 3.7’de titreşimin reel büyüklük - frekans ve imajiner büyüklük - frekans grafikleri gösterilmektedir. Şeklin üstünde yer alan reel büyüklük grafiğine bakılarak sistemin doğal frekansları yorumlanabilmektedir. Şeklin alt kısmında yer alan imajiner büyüklük grafiği ise titreşimin transfer fonksiyonun faz değişimine dair bilgi içermektedir. Bunun yanında imajiner kısım grafiğine bakılarak optimize edilecek noktaların seçimine dair referans oluşturulabilmektedir.



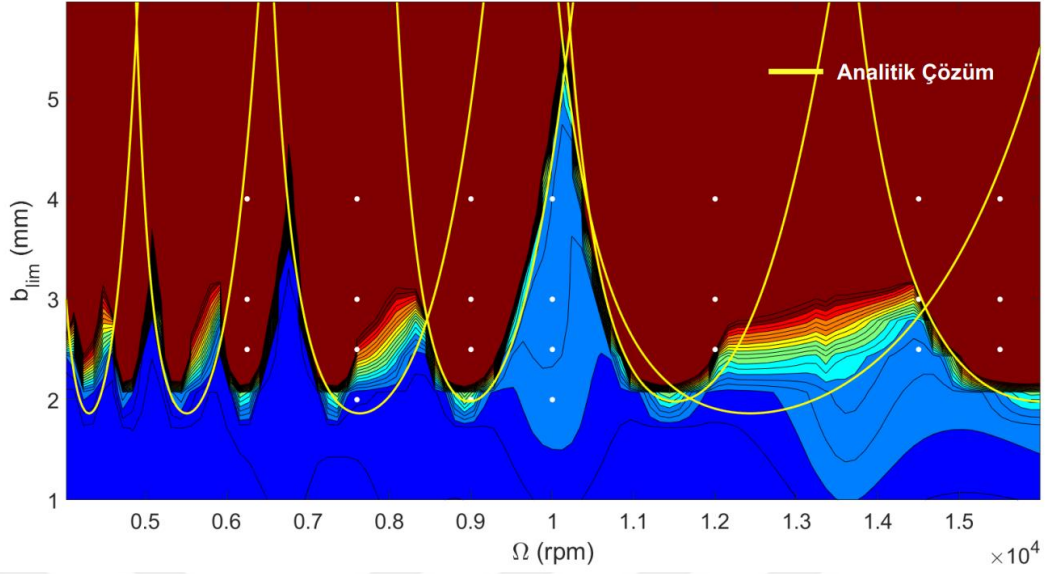


Şekil 3.7: Modal analiz sonucunda sisteme ait sanal (a) ve gerçek (b) büyüklük grafikleri

3.2 Stabilite Lobları

Stabilite loblarının çıkarılmasında bölüm 2.4.1’de gösterilen yöntemin yanında, zamana bağlı simülasyonları temel alan numerik çözüm kullanılmıştır. Bu SLD Şekil 3.8’de verilmiştir. Şekilde görüldüğü gibi Fourier seri açılımına dayanan model ile tez kapsamında yapılan numerik çözümün birbirine oldukça yakın olduğu gözükmemektedir. Bölüm 2.4.1’de gösterilen yöntem ile hesaplanan SLD’ler sarı çizgi ile gösterilmektedir. Kahve rengi kısımlar tırlama durumlarını gösterirken, kalan kısımlar kararlı bölgeleri ifade etmektedir. Analitik çözüm için ise benzer şekilde lob çizgilerinin üzerinde kalan kısımlar kararlı bölgeleri göstermektedir.

Özellikle 6500 devir sonrasında çözümlerin daha da yakınlaştığı görülmektedir. Bu farkın temel sebebi düşük kesme hızlarında proses sönümlenmesi (*process damping*) etkisinin görülmesidir. Tüm bunlara dayanarak, kesme parametrelerinin belirlenmesinde, Smith ve Tlustý tarafından geliştirilen kendini yenileyen kuvvet modeli (*regenerative force model*) sayesinde elde edilen SLD tercih edilmiştir. Renk cetveli oluşturmak üzere, lobların hesaplanmasında kullanılan simülasyon verilerinin RMS değerleri hesaplanmıştır. Bu sayede kararlı ver tırlama durumları arasındaki geçiş daha detaylı olarak görülebilmektedir [58].



Şekil 3.8: Numerik çözüm ve Fourier seri açılımına dayalı analitik çözümden elde edilen SL

3.3 Kesme Verisi Toplama Sisteminin Hazırlanması

Kesim esnasında meydana gelen titreşim bilgilerinin toplanması için iş mili muhafazasının üzerine bir ivmeölçer tutturulmuştur. İvmeölçer olarak PCB Piezotronics 356A15 modeli kullanılmıştır. Bahsi geçen ivmeölçere ait teknik özellikler Çizelge 3.6’da verilmiştir.


Çizelge 3.6: İvmeölçere ait teknik özellikler.

İvme ölçer	
Hassasiyet	10,2 mV/(m/s ²)
Ölçüm genişliği	490 m/s ² (max)
Frekans aralığı	2-5000 Hz
Doğal Frekans	≥ 25kHz

İvmeölçer takım tezgâhı üzerine yerleştirilirken konumunun kesme yönüne paralel olmasına dikkat edilmiştir. Bu yerleşim, kesici uçların malzeme ile temas edeceği ilerleme yönlerinden gelen titreşimlerin toplanması amacıyla tercih edilmiştir.

Sensörlerden gelen veri akışını toplamak üzere çoklu veri alımına imkân sağlayan NI (National Instruments) 9234 veri toplama modülü üzerine kullanılmıştır. Bu modüle

güç sağlaması ve modül ile harici bilgisayar arasında bağlantı kurulmasını sağlamak üzere ise NI 9178 Compact DAQ şasisi kullanılmıştır. Kesim arasında iş parçasının tezgah üzerindeki yerleşimi, ivme ölçerin iş mili muhafazası üzerindeki konumu ve ivmeölçerin bağlandığı modül, şasi ve bilgisayardan oluşan deney toplama düzeneği Şekil 3.9’da gösterilmektedir.

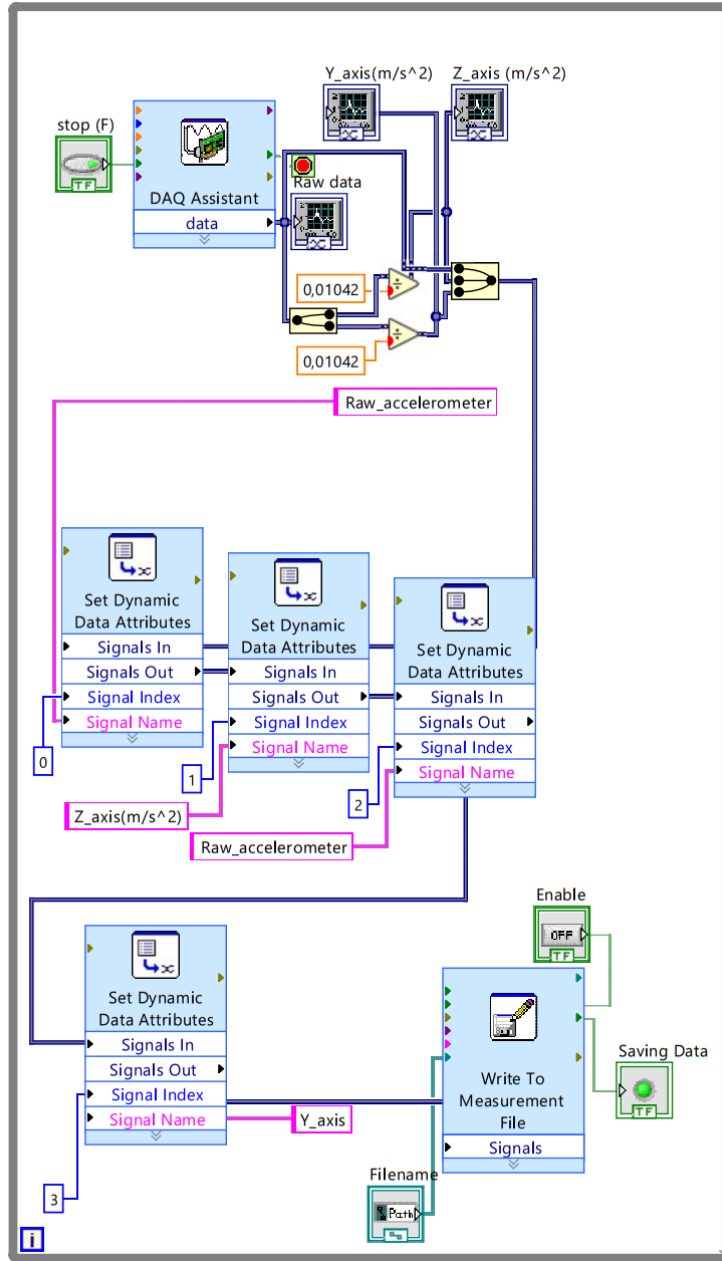


Şekil 3.9: Deney düzeneği

3.3.1 Veri toplama yazılımı

Veriler, ivmeölçer ve mikrofondan NI 9234 modülünün maksimum örnekleme hızı olan 51200 Hz lik hızlarda toplanmıştır. Yazılım tarafında ise NI modülleri ile bilgisayarın entegrasyonunu sağlayan Labview uygulamasından yararlanılmıştır. Labview uygulaması kullanılarak oluşturulan, titreşim verilerinin iki eksende eş zamanlı olarak toplamasını sağlayan sistem mimarisi oluşturulmuştur. Bahsedilen

mimariye ait blok diyagram şeması Şekil 3.10’da gösterilmektedir. Toplanan veriler farklı formatlarda kaydedilebilmektedir.



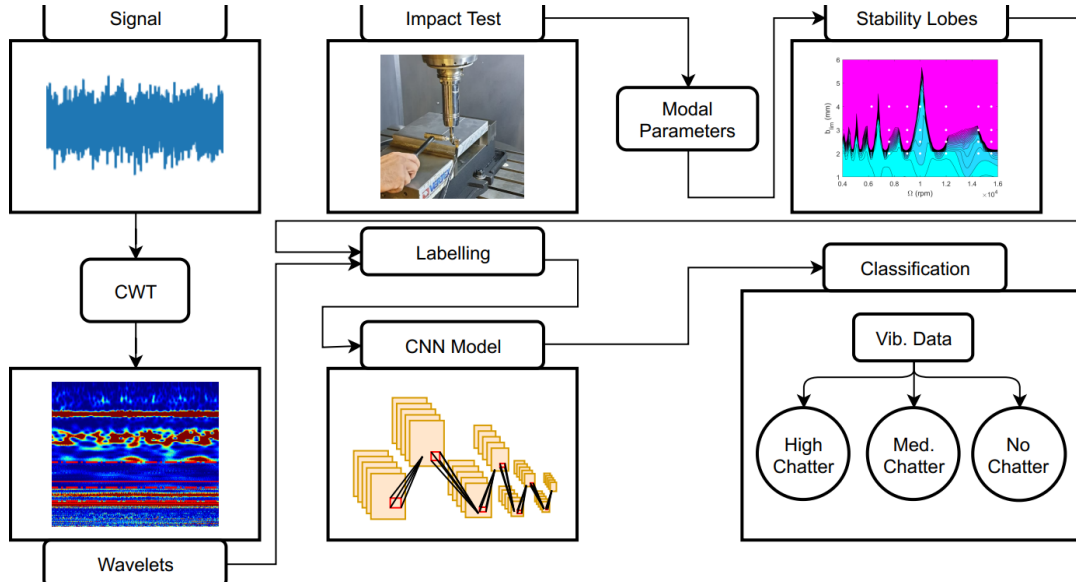
Şekil 3.10: Veri toplama işlemlerinde kullanılan Labview blok diyagramı

3.4 Tırlama Tespiti Analizi

Bu bölümde geliştirilen özgün tırlama tespit yöntemin içerisinde yer alan adımlar anlatılmıştır.

3.4.1 Tez kapsamında geliştirilen özgün analiz metodu

Bu çalışma kapsamında SLD dalgacıklar ve CNN'e dayalı akıllı bir tırlama algılama yöntemi geliştirilmiştir. Bu algılama yönteminin genel akışı Şekil 3.11'de sunulmuştur. Başlangıçta, takım-tutucu-iş mili sisteminin dinamik parametreleri darbe (çekiç) testi ile belirlenir. SLD'nin oluşturulması için modal parametreler (dinamik parametreler) gereklidir. SLD elde edildikten sonra deney setinin hazırlanmasında kullanılacak kesme parametrelerinin belirlenmesi için kullanılmıştır. Burada amaç, toplanacak verilerin içinde stabil, geçiş ve tırlama durumlarının oluşacağını garanti altına almaktır. Deney parametrelerinin belirlenmesinin ardından kesimler gerçekleştirilmiştir. Kesimler 0.1 saniye uzunluğunda parçalara bölünerek her parçanın dalgacık dönüşümü elde edilmiştir. SLD'ler ve elde edilen dalgacıkların peyderpey incelenmesi sonucunda veri etiketleri belirlenmiştir. Etiketler öncelikle SLD'ye göre seçilir. Bununla birlikte, bazı dalgacıklar, geçiş durumunda tırlama (orta düzey tırlama) gösteren kesimler için uygun etiketleri belirlemek üzere ayrı ayrı incelenmiştir. Son olarak belirlenen etiketler ve hazırlanan veri seti kullanılarak modelin eğitim ve testleri gerçekleştirilmiştir. Tüm bu işlemlerin arasındaki ilişkiyi gösteren akış şeması Şekil 3.11'de verilmiştir.



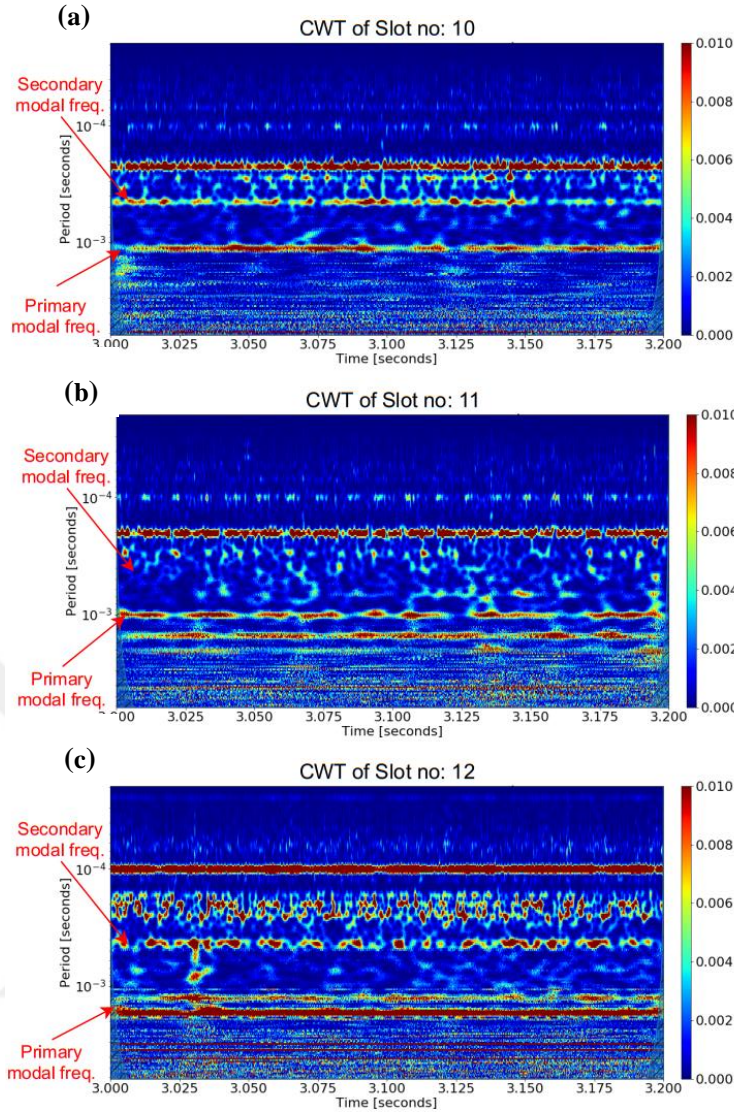
Şekil 3.11: Tırlama algılama yöntemine ait akış şeması [3]

Freze işlemlerinde tırlamanın analitik olarak tahmini üzerine en uygun referanslardan biri olan stabilite lobları, uygun bir veri setinin hazırlanması için kullanılmıştır.

Stabilite lobları sayesinde kesim işlemleri henüz gerçekleştirilmeden, kesme parametrelerinin tırlama olan etkisi tahmin edilmektedir. Veri setinin zenginliğini arttırmak ve kullanılan modelin gerçek uygulamalarda yararlanabilir durumda olması için, farklı tırlama durumlarını içerisinde barındıracak kesimlerin yapılması önemlidir. Buna istinaden 4mm kesme derinliği ve deneylerde kullanılan freze tezgahının maksimum çalışma devri olan 16000 rpm bölgesi seçilerek, bu bölgeye ait stabilite lobları elde edilmiştir. SLD'leri elde etmek için ilk olarak tezgahın dinamik özelliklerinin belirlenmesi gerekmektedir. Bu özellikleri çıkarmak üzere tezgaha çekiç testleri uygulanmıştır.

3.4.2 Veri etiketlerinin belirlenmesi

Veri toplama sisteminin de ayarlanmasının ardından son aşama olarak kesim noktaları Stabilite lobları üzerinde belirlenmiştir. Her nokta için deneyler gerçekleştirilerek veriler toplanmıştır. Akabinde toplanan veriler parçalara ayrılarak dalgacık dönüşümleri elde edilmiştir. Tüm dalgacık dönüşümleri ayrı ayrı incelenerek SLD grafiklerindeki tırlama durumları ile karşılaştırılmıştır., 8000 dd'den daha düşük hızlarda dalgacıklarda titreşimin tespit edilemediği ve düşük hızın yeterli amplifikasyon oluşturmadığı görülmüştür. Shrivastava ve Singh, dönüş deneylerinde de benzer bir sonucun altını çizmiştir. İş mili hızı ve kesme derinliğinin tırlamadan kaçınmak için düşük veya orta düzeyde tutulması gerektiğini öne sürdüler [20]. Bununla birlikte, 8000 dd'den daha yüksek hızlarda, çıkarılan dalgacıklar, her kesim için kesimin orta ve son bölümlerinde karşılaştırıldığında, doğal frekanslar etrafında önemli bir titreşim amplifikasyon görülmüştür. Bu durum tırlamanın meydana geldiğine dair önemli bir kanıt olmakta ve SLD'ler ile tutarlılık göstermektedir.



Şekil 3.12: 10, 11 ve 12 nolu kesimler üzerinde tırlama yok (a), orta düzey tırlama (b) ve yüksek düzey tırlamanın (c) gösterilmesi.

Örneğin 10, 11 ve 12 numaralı olmak üzere üç farklı kesimden gelen dalgacıklar karşılaştırılarak, sistemin birinci ve ikinci doğal frekanslarına yakın titreşim genliklerinin tırlama ile arttığı Şekil 3.12’de görülebilir. Benzer davranışlar, farklı yöntemlerle tırlama tanımlama üzerinde çalışan çok sayıda araştırmacı tarafından daha önce gözlemlenmiştir [16, 17, 53, 57, 58]. Darbe çekicinin ölçüm frekansı aralığı 0-5000 Hz olduğundan, bu frekansın ötesinde herhangi bir amplifikasyonu sistemin dinamik parametrelerine atfetmek imkansızdır. SLD'nin de belirttiği gibi, tırlama titreşimlerinin oluşumları, deneylerde kullanılan sistemin doğası gereği 10000 RPM gibi kararlı bölgelerde artan iş mili hızı ile ters orantılı olabilir. Bu karşı-sezgisel davranış, Şekil 3.12’de verilmiş olan dalgacık örneklerinde gözlemlenebilir. Kesim 10 bir sonraki kesim olan kesim 11’e göre daha düşük iş mili devrinde ve aynı kesme

derinliğinde işlenmiştir. Bu duruma rağmen kesim 11 tezgahın dinamik yapısından dolayı kararlı bölgeye gelen iş mili devrinde kesildiği için titreşimlerin düşüşü gözlemlenmektedir. Örnekte verilen dalgacıklar, artan iş mili hızları ve tırlama ile ilgili titreşimlerin doğrusal olmayan değişikliklerinin mükemmel örnekleridir. Veri setinde yer alan kesimlere ait etiketler SLD ve dalgacıkların karşılaştırması sonucunda belirlenmiş ve Çizelge 3.7’de verilmiştir.

Çizelge 3.7: Deneylere ait kesme parametreleri ve tırlama etiketleri.

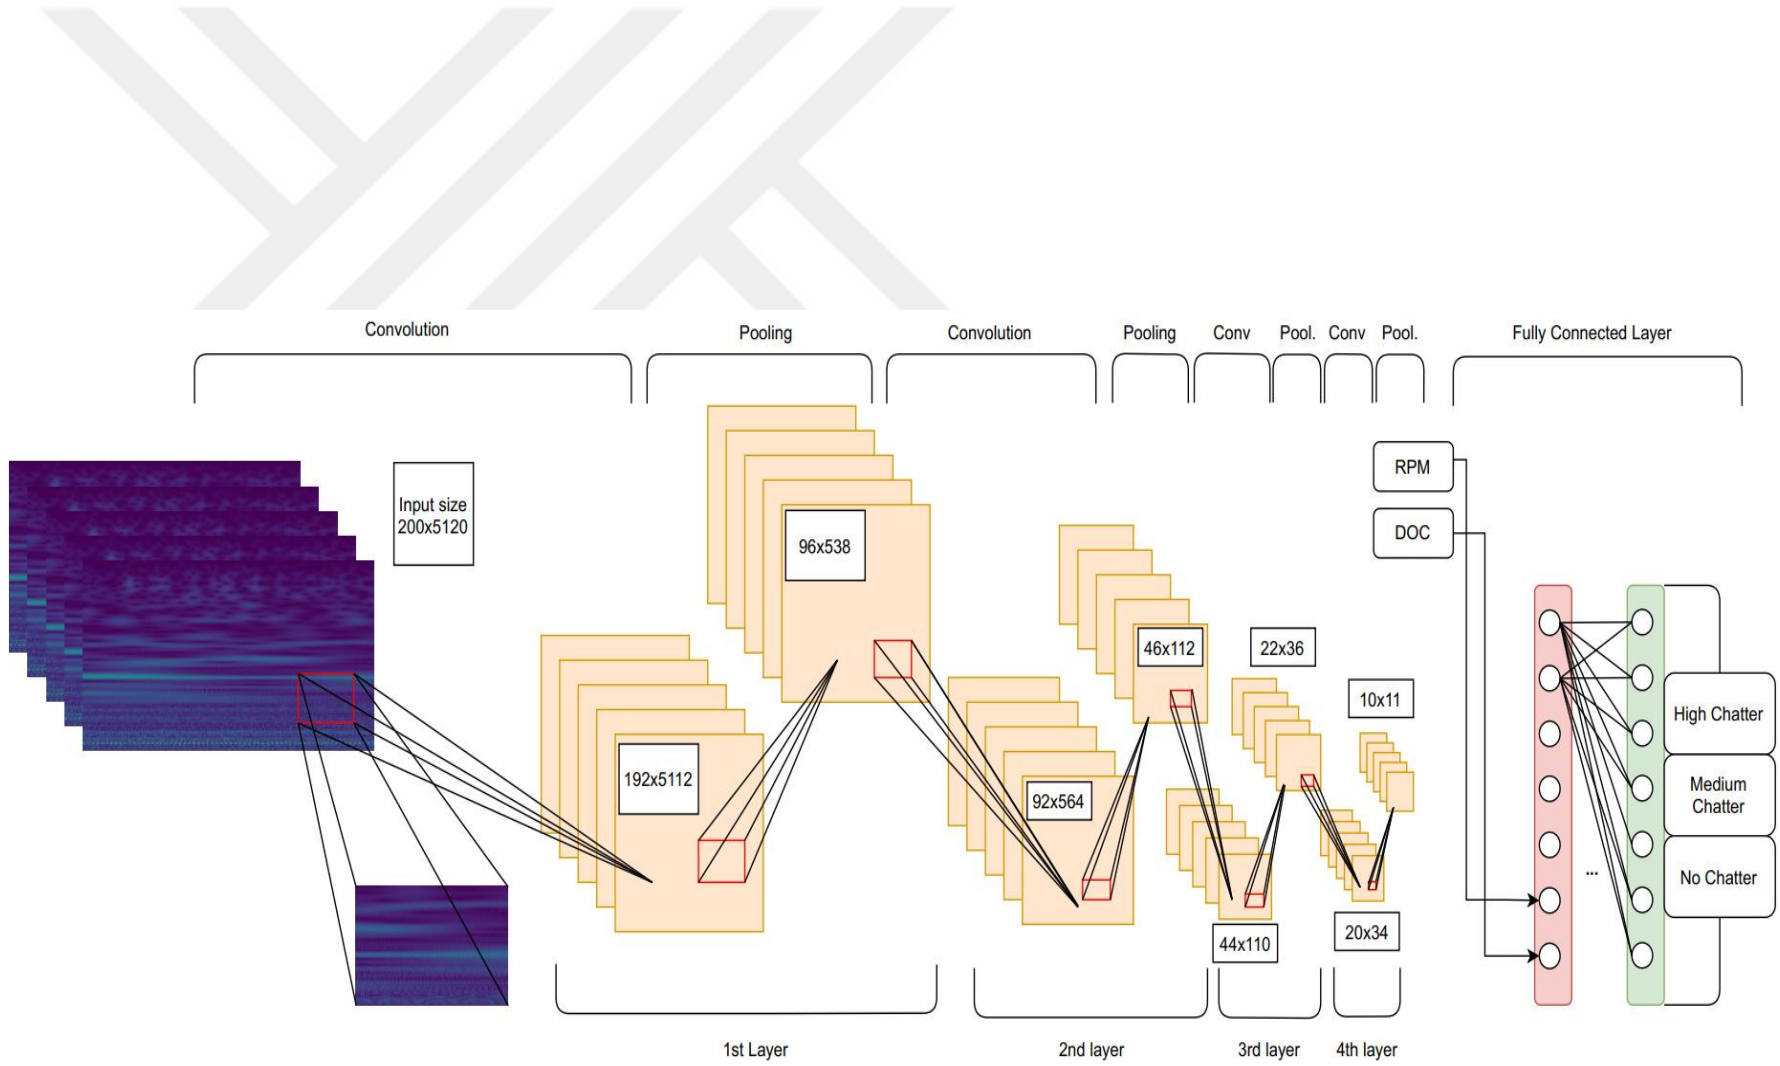
Kesim No	İş mili hızı (rpm)	Kesme Hızı (m/dak)	Kesme derinliği (mm)	Etiket
1	6250	122,72	4	NC
2	7600	149,23	4	NC
3	9000	176,71	4	MC
4	10000	196,35	4	NC
5	12000	235,62	4	HC
6	14500	284,71	4	HC
7	15500	304,34	4	HC
8	6250	122,72	3	NC
9	7600	149,23	3	NC
10	9000	176,71	3	MC
11	10000	196,35	3	NC
12	12000	235,62	3	HC
13	14500	284,71	3	HC
14	15500	304,34	3	HC
15	6250	122,72	2,5	NC
16	7600	149,23	2,5	NC
17	9000	176,71	2,5	MC
18	10000	196,35	2,5	NC
19	12000	235,62	2,5	MC
20	14500	284,71	2,5	MC
21	15500	304,34	2,5	HC
22	6250	122,72	2	NC
23	7600	149,23	2	NC
24	9000	176,71	2	MC
25	10000	196,35	2	NC

3.5 CNN Model Mimarisi

Bu çalışmada, verilerin dalgacık dönüşümleri girdi olarak kullanılmıştır. Bunlar, modele 4 dalgacıktan oluşan partiler halinde verilmiştir. Dalgacık görselleri model için girdi matrislerine dönüştürülürken, dalgacıkların yüksek boyutlarından dolayı (200x5120) modelde çok fazla sayıda parametreler oluşturmaktadır. Dalgacık boyutları örnekleme frekansı ve CWT elde edilirken kullanılan ölçek sayısından dolayı bu şekildedir. Tez kapsamında kullanılan CNN mimarisi, 4 konvolüsyon katmanı ve 4 tam bağlantılı katmandan oluşur. İlk katmanda 9x9 boyutunda çekirdek (kernel) filtresi kullanılmış, padding sıfıra ayarlanmış ve konvolüsyon işlemi için adım 1x1 olarak belirlenmiştir, bu işlemi sisteme doğrusallık dışı (non-linear) özellik sağlayan ReLU aktivasyon fonksiyonu takip etmektedir. Daha sonra 2x9 çekirdek boyutuna sahip havuzlama katmanı (max-Pooling) kullanılır. Daha sonra, 5x5,3x3,3x3 çekirdek filtreleriyle konvolüsyon işlemleri; sırasıyla katman 2, katman 3 ve katman 4 için 2x5, 2x3 ve 2x3 pencereci havuzlama ve ReLU aktivasyonu kullanılarak yapılır. Havuzlama operatörlerinin (filtrelerinin) şekli, girdi görüntülerinin asimetrikliğinin üstesinden gelmek için dikdörtgen olarak seçilir. Aşırı uyum (over-fit) sorununun üstesinden gelmek için modelde bırakma (dropout) oranları 0,2 olarak belirlenmiştir. Sınıflandırma tam bağlantılı katmanlarda yapılmıştır. Bu katman blokları sınıfların logitlerini verir, bu nedenle Eşitlik 3.1'de ifade edilen Softmax, bu logitleri 0 ile 1 arasında sıkıştırmak için kullanılmıştır.

$$\text{softmax}(x)_i = \frac{\exp(x_i)}{\sum_{j=1}^n \exp(x_j)} \text{ for } i = 0,1,2 \dots \dots, k \quad (3.1)$$

Bu çalışmaya özel olarak ayrıca, mevcut kesme parametreleri olan kesme derinliği ve iş mili devrini kullanmak için, modelin sonunda yer alan tam bağlantılı katmanlarda değişiklikler yapılmıştır. Tam bağlı katmanda giriş vektörünün boyutunu 2 artırarak, normalize edilmiş kesme derinliği ve iş mili hızı değerleri, tambağlı katmanın girişine dahil edilebilmiştir. Şekil 3.13'te, geliştirilen CNN modelinin genel mimarisini sunmaktadır. Katmanların tüm giriş ve çıkış boyutlarının ve tam bağlı katmanlar gösterilmektedir. Bunun yanı sıra giriş ve çıkış vektörlerinin her katman içerisindeki tam boyutları ve bunlara karşılık gelen parametre sayıları Çizelge 3.8'de gösterilmiştir.



Şekil 3.13 CNN Modeline ait mimari ve katman ölçüleri

Çizelge 3.8: CNN model mimarisini.

Katman Tipi	Çıkış Boyutu	Parametre Sayısı
Conv2d-1	[4, 32, 192, 5112]	2624
ReLU-2	[4, 32, 192, 5112]	0
MaxPool2d-3	[4, 32, 96, 568]	0
Conv2d-4	[4, 16, 92, 564]	12816
ReLU-5	[4, 16, 92, 564]	0
MaxPool2d-6	[4, 16, 46, 112]	0
Conv2d-7	[4, 8, 44, 110]	1160
ReLU-8	[4, 8, 44, 110]	0
MaxPool2d-9	[4, 8, 22, 36]	0
Conv2d-10	[4, 4, 20, 34]	292
ReLU-11	[4, 4, 20, 34]	0
MaxPool2d-12	[4, 4, 10, 11]	0
Linear-13	[4, 110]	48730
Dropout-14	[4, 110]	0
Linear-15	[4, 110]	11100
Dropout-16	[4, 110]	0
Linear-17	[4, 10]	1010
Dropout-18	[4, 10]	0
Linear-19	[4, 3]	33

Bunlara ek olarak, modele ait hiper parametrelerde Çizelge 3.9'da verilmiştir.

Çizelge: 3.9: CNN hiper parametreleri.

Hiperparametreler	
Öğrenme oranı (Learning rate)	0.001
Posta boyutu (Batch size)	4
İterasyon Sayısı (Number of epochs)	8
Optimizasyon aracı	<i>Adam</i> ($\beta_1 = 0.9, \beta_2 = 0.999$)
Bırakma oranı (dropout rate)	0.2

CNN algoritması için pseudo kod Çizelge 3.10'da verilmiştir. Bu kod, Çizelge 3.8'de verilen yapıyı anlamının alternatif bir yolunu sunmaktadır. CNN algoritması 4 katmandan oluşur. Her katman için çıktı vektörleri F_i 'dir. Bir katman için, W_i ve B_i ağırlık ve önyargı (weight and bias) değerlerine karşılık gelmektedir.

Çizelge 3.10: CNN modeline ait pseude kod.

Algorithm 1: Training and test procedure
of the [DCNN](#)

```

train()
  Result: Trained model parameters  $W$ 
1   $X \leftarrow$  Wavelet images
2   $Y \leftarrow$  Chatter labels for corresponding  $X$ 
3   $W \leftarrow$  The weights of the model initialized by
   randomly sampling from Gaussian Distribution
   ( $\mu = 0, \sigma = 0.001$ )
4  for  $k=1$  to epoch do
5    for  $i=1$  to number of images do
6       $\hat{Y}^{(i)} \leftarrow W^T X^{(i)}$ 
7       $L \leftarrow \text{CE}(\hat{Y}^{(i)}, Y^{(i)})$ 
8       $W \leftarrow W - \eta \cdot \nabla_W L$ 
9    end
10 end

test()
  Result: Prediction of the chatter
1   $x \leftarrow$  Wavelet image
2   $y \leftarrow$  Chatter label for corresponding  $X$ 
3   $W \leftarrow$  The weights of the trained model
4   $\hat{y} \leftarrow W^T x$ 
5   $L \leftarrow \text{CE}(\hat{y}, y)$ 

```



4. DENEYSEL ÇALIŞMALAR VE DEĞERLENDİRME

Bu bölümde birçok farklı metrik ve araç kullanarak CNN modelinin sonuçları irdelenmiştir. Asıl test senaryolarını belirlemeden önce modeli en çok zorlayacak kesimler saptanmıştır. Yapılan bu çalışmalarda CNN modelinin endüstriyel alanlarda kolay uyarlanabilmesi amaçlanmıştır.

4.1. Kayıp Fonksiyonları ile Veri Setinin İrdelenmesi


Makine öğrenimi işlemlerinde modelin eğitim aşamasını gerçekleştirirken, eğitim verilerinin var olan veri seti içerisindeki boyutunu ve çeşitliliğini dikkate almak çok önemlidir. Öğrenme aşamasında daha çok veri kullanmak test başarılarını arttırır da sınırlı bir veri içerisinde eğitim veri setinin çok geniş olması, test veri sayısının azalmasına ve modelin haliyle daha iyi tahmin yapmasına sebep olmaktadır. Her ne kadar bu durum daha yüksek tahmin doğruluklarına sebep olsa da sistemin endüstriyel kullanımdan uzaklaşması ve mükemmel şartlarda nasıl çalıştığının bir gösterimi olmasından öteye gitmemektedir. Tüm bunlar göz önüne alınarak, sistemin asgari düzeyde veri ile eğitilmesi ve gerçekçi test senaryoları üzerinden elde edilen sonuçların irdelenmesi gerekmektedir.

Tırlama seviyeleri, kesme hızı ve derinliği ile ilgili olarak ciddi ve beklenmedik şekilde değişebilmektedir, bu durum SLD üzerinde de gösterilmiştir. Kesme hızlarındaki ufak değişimler sistemin titreşim davranışlarını ciddi ölçüde etkilemektedir. Bu durum göz önüne alındığında her tırlama durumu için gerekli ölçüde eğitim verisi olması, test sonuçlarında yüksek doğruluk elde etmek için zorunludur. Ancak kesim verilerini karıştırmadığımızdan, eğitim ve test verilerini dikkatlice ayrılmadık, bu ayırım yapılırken özellikle sınıflandırması zor olan verilerin muhakkak bir kısmının test verileri içerisinde yer alması gerekir. Aksi takdirde sistemin gerçek bir problem karşısında başarı göstereceğini iddia etmek mümkün olmayacaktır. Buna istinaden model için tırlama durumlarının tahminin zor olduğu kesimlerin belirlenmesi amaçlanmıştır. Belirlemenin başarılması için çapraz entropi değerlerine dayalı sistematik bir değerlendirme geliştirilmiştir. Pozitif ve negatif etiketli belirli bir

girdi örneğinde, y'nin bunların doğru etiketi olduğu varsayılarak, çapraz entropi kaybı fonksiyonu, eşitlik 4.1'deki gibidir.

$$L = -\frac{1}{N} \sum_{n=1}^N [y_n \log(\hat{y}_n) + (1 - y_n) \log(1 - \hat{y}_n)] \quad (4.1)$$

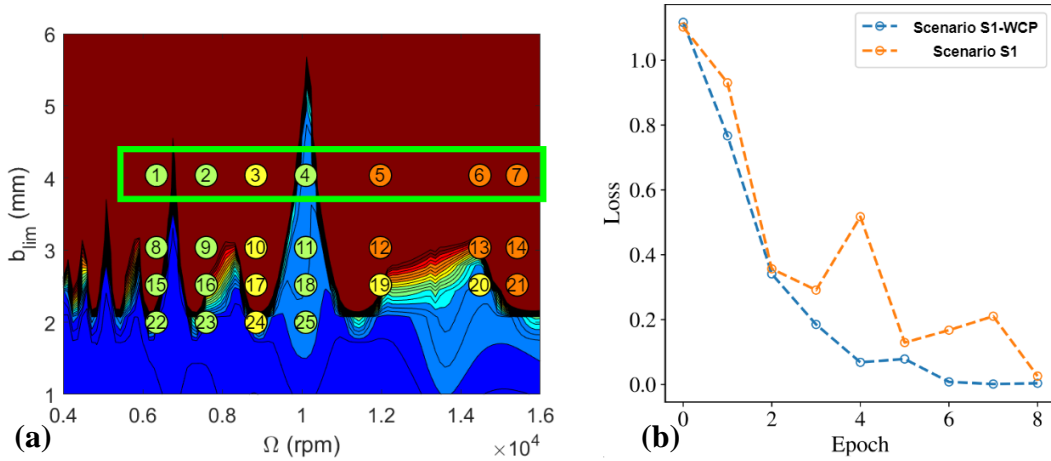
\hat{y} modelin tahmin edilen veri için tahminin olasılığını temsil eder ve N örnek sayısını temsil eder. Sistemik olarak, her kesim tek bir test verisi olarak kullanılır ve algoritma kalan 24 kesim ile eğitilir. Her eğitimin kayıp değerleri hesaplanmış ve sonuçlar Şekil 4.1'de gösterilmiştir. Burada SLD grafiklerinde olduğu gibi her test verisi için hesaplanan kayıp değerleri iş mili devri ve kesme deriliği parametrelerine göre bir kabarcık haritası olarak sunulur. Kabarcıkların boyutu kayıp değerlerini temsil eder. Grafiği inceleyerek, 10000 devirde gerçekleştirilen kesimler CNN için önceden tahmin etmesi en zor verilerdir. Bu durum SLD grafiği üzerinde yine 10000 devirde bulunan stabil bölge ile uyum içindedir. Kayıp değerleri haritasını kullanarak, eğitim ve test numunelerinin seçimini daha bilinçli bir şekilde gerçekleştirilebilmiştir, böylece değerlendirmedeki eğitim ve test setleri üç ayrı tırlama durumu içinde bu durumları temsil edecek verileri içlerinde barındırmışlardır.



Şekil 4.1: Tekli test ortamında kesimlerin kayıp değerleri

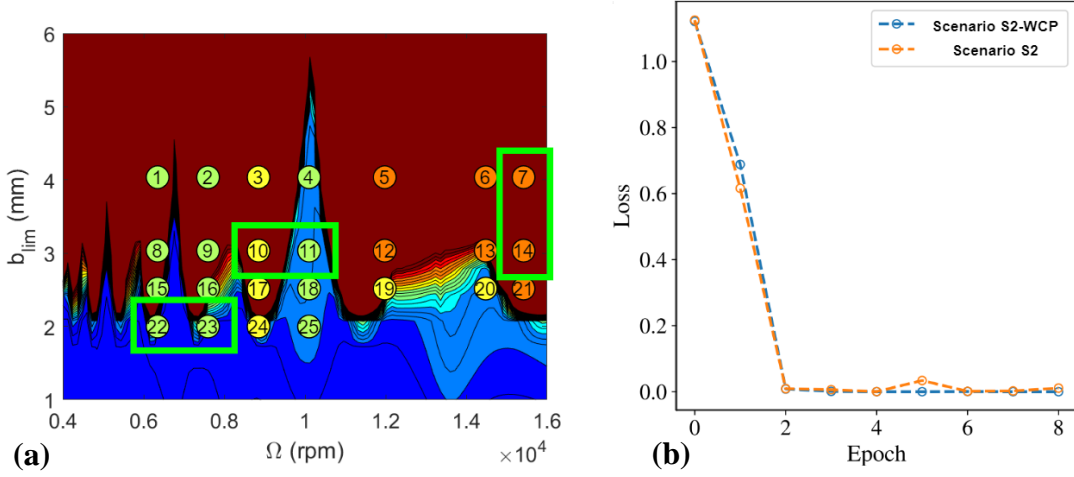
4.2. Eğitim ve Doğrulama Senaryolarının Belirlenmesi

CNN'nin performansını test etmek için S1, S2 ve S3 olarak üç farklı senaryo belirlenmiştir. Bu senaryolarda, CNN sadece dalgacıklar ile ve dalgacıkların yanında kesme parametreleri (WCP) kullanılarak test edilmiştir. Tespit performansının ortak bir göstergesi olarak, test dizisi sırasında her senaryonun doğrulama kaybı birbiriyle karşılaştırılmıştır. Şekil 9a'da, S1 için seçilen veri noktalarını göstermektedir. Bu senaryoda, özellikle, eğitim veri setinde 4 mm derinliğinde dalgacıklar kullanılmamıştır. Algoritma 4 mm derinlik örnekleriyle eğitilmemiş olsa da test sırasında daha önce eğitimde hiç görmediği kesimleri minimum kayıpla sınıflandırabilmiştir. Buna ek olarak tam bağlı katmanda kesme parametrelerini de eklenerek, Şekil 4.2'de gösterildiği gibi erken dönemlerde test kayıpları azaltılmıştır.



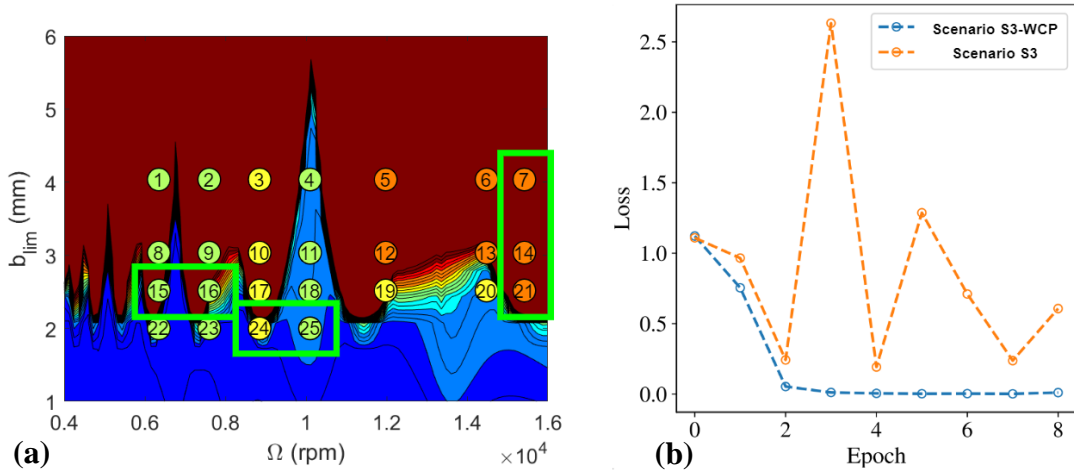
Şekil 4.2: S1 için SLD ve test kesimleri (a), test kaybı dönem grafiği (b)

Şekil 4.3, S2 için seçilen veri noktalarını ve test sonuçlarında kayıp değerlerini göstermektedir. Bu senaryoda, test verileri çeşitli şekillerde seçilmiştir. Kayıp değeri eğrileri, hem dalgacıkların hem de dalgacıkların kesme parametreleri ile birlikte verildiğinde çok iyi performans gösterdiğini ortaya koymaktadır. Şekil 4.3'te gösterildiği gibi her iki durumda da bu ikinci iterasyondan itibaren test kayıpları azalmıştır.



Şekil 4.3: S2 için SLD ve test kesimleri (a), test kaybı dönem grafiği (b)

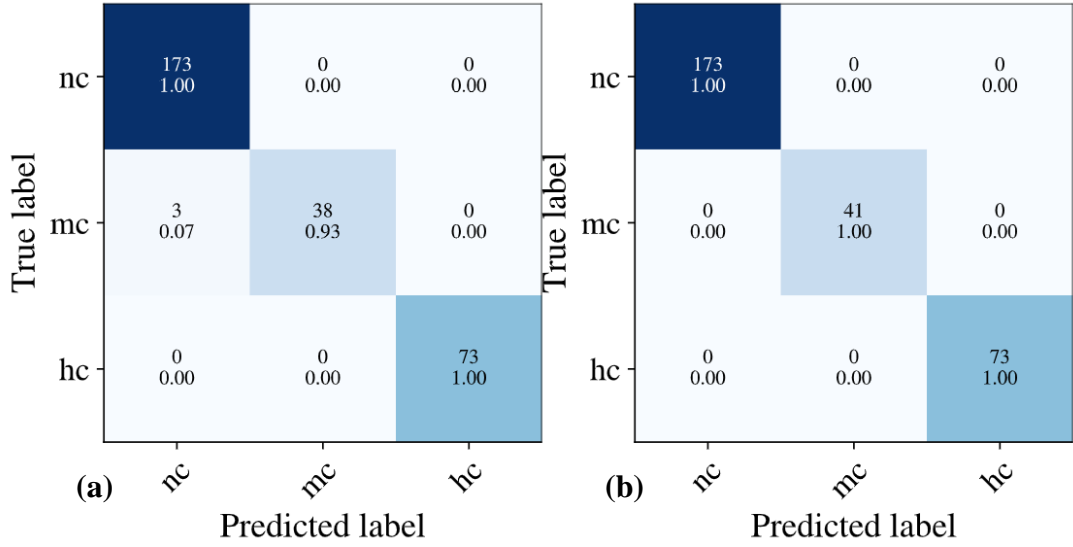
Şekil 4.4, S3 için seçilen veri noktalarını ve test sonuçlarında kayıp değerlerini göstermektedir. Bu senaryoda, tüm veriler içinden yedi adet test verisi seçilmiştir. Model, en az sayıda eğitim verisi gördüğünden en düşük doğruluğu elde etmiştir. Ancak, yalnızca dalgacıklar ve dalgacıklar ile beraber kesme parametreleri kullanımı arasındaki en önemli fark bu senaryoda meydana gelmiştir. Test kayıp değerleri sadece dalgacıklar kullanıldığında dalgalanmaya devam ederken, kesme parametreleri modele girdi olarak eklendiğinde kayıplar çok hızlı bir şekilde azalmıştır. Kayıp değerlerinin değişimi Şekil 4.4'te gösterilmektedir.



Şekil 4.4: S3 için SLD ve test kesimleri (a), test kaybı dönem grafiği (b)

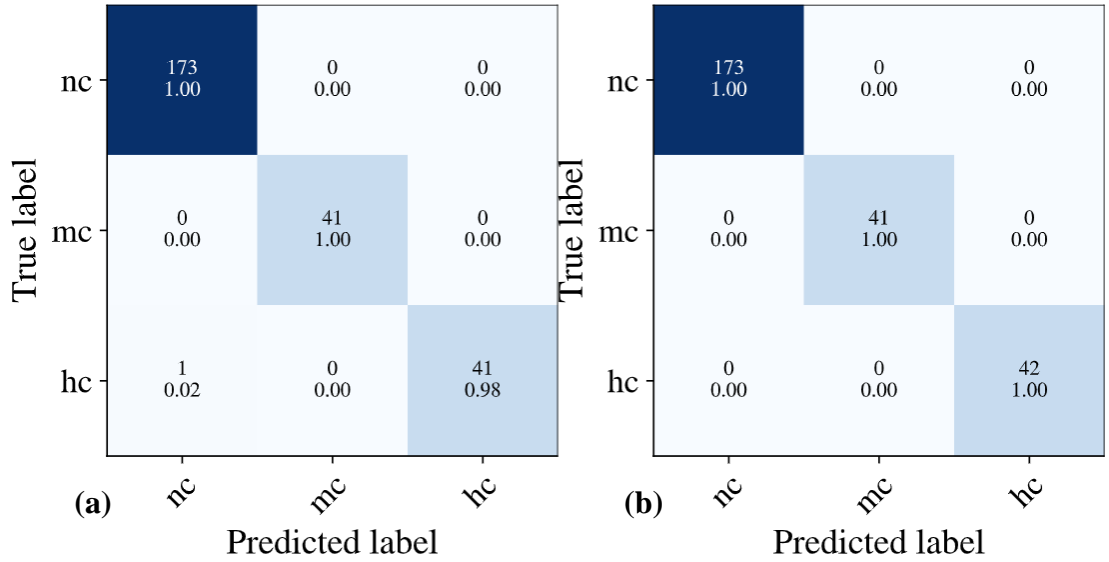
Karışıklık matrisleri her senaryonun tahmin sonuçlarına olan etkisi gözlemlemek için kullanışlıdır. Sadece dalgacıkların ve dalgacıklar ile beraber kesme parametrelerinin girdi olarak kullanılmasının modelin tahmin performansına etkisi Şekil 4.5'de

verilmiştir. S1 için Algılamanın doğruluğu, algoritmaya kesme parametreleri eklenerek artırılmış ve %100 doğruluğa yükselmiştir.



Şekil 4.5: S1 (a) ve S1-WCP (b) senaryoları sonuçlarında karmaşıklık matrisleri

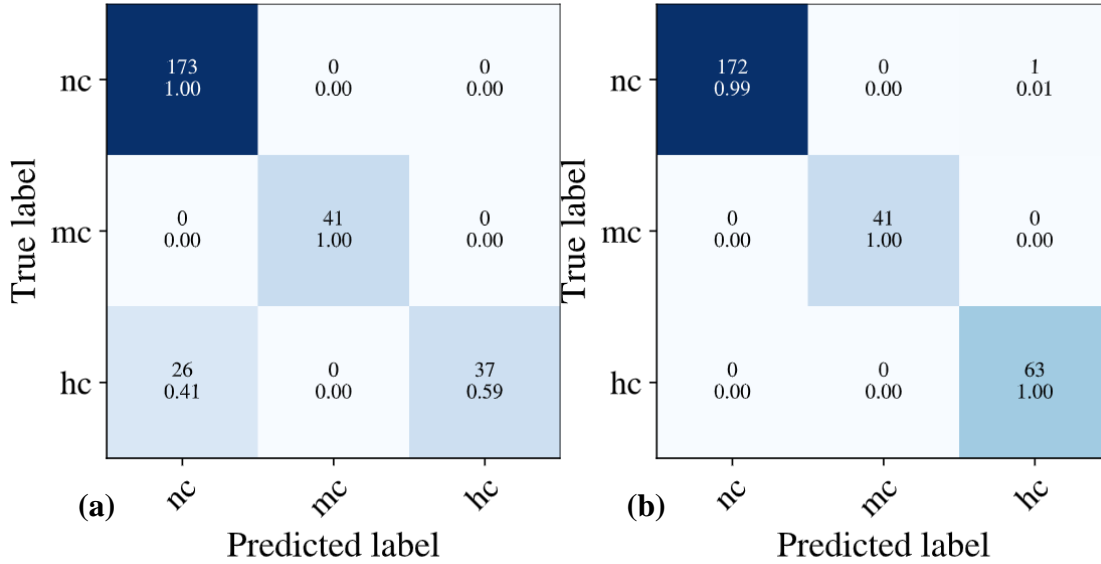
S2 için, her iki durumda da doğruluk hemen hemen aynıdır, yalnızca dalgacıkta % 99 ve % 100 WCP'de. Sonuçlar Şekil 4.6'da verilmektedir.



Şekil 4.6: S2 (a) ve S2-WCP (b) senaryoları sonuçlarında karmaşıklık matrisleri

CNN'nin en çok zorlandığı son senaryo S3'te, Şekil 4.7'de gösterilen WCP senaryolarında doğruluk neredeyse %10 artmıştır. Bu senaryoda ayrıca, daha fazla test verisi dahil etmenin ve eğitim setini azaltmanın performansı engellediğini, ancak

kesme parametrelerinin eklenmesinin bu olumsuz etkiyi hafiflettiğini görülmektedir. Yalnızca giriş olarak dalgacıklar ve WCP ile S1, S2 ve S3 test kesimlerini içeren üç farklı senaryonun test doğruluğu Çizelge 4.1'de gösterilmektedir.



Şekil 4.7: S3 (a) ve S3-WCP (b) senaryoları sonuçlarında karmaşıklık matrisleri

Kayıp değerlerine ve doğruluğuna ek olarak çeşitli performans ölçütleri mevcuttur. Öngörülen CNN modeli çok sınıflı bir sınıflandırma gerçekleştirdiğinden; kesinlik, geri çağırma ve f1 skoru yaygın olarak kullanılan, etkili ölçümlerdir [47]. Tüm sınıfları ve etiketlerinin eşdeğerini göz önünde bulundurarak, bu önlemler doğru veya yanlış etiket tanımlamalarını sayar. Eşitlik 4.2'de gösterilen hassaslık ölçüsü, sınıflandırıcılarınkilerle veri sınıfı etiketlerinin sınıf başına ortalama bir uyumsuzluğudur. Eşitlik 15'te gösterilen Geri Çağırma ölçüsü, sınıflandırıcı algoritmanın farklı sınıfları tanımlamadaki ortalama etkinliğidir. Son olarak, eşitlik 16'da gösterilen f1 Puanı ($\beta = 1$), verilerin gerçek sınıfı ile sınıf başına ortalamaya göre sınıflandırıcı algoritması tarafından verilenler arasında bir ilişki ölçüsüdür; burada gerçek konum, fp_i yanlış pozitif, fn_i yanlış negatif, Her sınıf için tn_i doğru negatif ve i sırasıyla sınıfların sayısını gösterir. Tüm performans ölçütleri ve algılama doğruluğu Çizelge 4.1'de verilmiştir. S3 için fark edilebilir daha düşük kesinlik ve geri çağırma değerleri vardır. Bunun arkasındaki sebep, 21 numaralı kesimdir. Şekil 4.4'de gösterildiği gibi, bu özel kesim hem kesme derinliği hem de iş mili hızı açısından stabil

bölgelere çok yakındır. Bu durum, modelin 21 numaralı kesim için etiketleri yanlış tahmin etmesine neden olmaktadır.

Geliştirilen CNN yöntemi, doğruluk açısından daha önce geliştirilen DMLP modeli ile de karşılaştırılmıştır [24]. Önerilen DMLP, istatistiksel sinyal yalnızca özelliklerinden ve kesme parametrelerinden yararlandığından, önemli bir performans farkı oluşmuştur. Bu, her modeldeki girdi türleriyle oldukça ilgilidir. Dalgacıklar, istatistiksel özelliklere kıyasla daha zengin bilgi sağlar. Ayrıca, algoritmaya uygulanan kesme parametreleri performansı artırsa bile, girişler olarak yalnızca skaler değerleri kullanmak düşük doğruluklara neden olur. DMLP modeli kullanılarak her senaryonun doğruluk değerleri de Çizelge 4.1’de sunulmuştur.

$$\begin{aligned} \text{Tutarlılık} &= \frac{1}{n} \sum_{i=1}^n \frac{tp_i}{tp_i + fp_i} \\ \text{Anımsama} &= \frac{1}{n} \sum_{i=1}^n \frac{tp_i}{tp_i + fn_i} \\ F_\beta \text{ skoru} &= (\beta^2 + 1) \cdot \frac{\text{Precision} \cdot \text{Recall}}{\beta^2 \cdot \text{Precision} + \text{Recall}} \end{aligned} \quad (4.2)$$

Çizelge 4.1: Senaryolara göre performans metriği değerleri ve %doğruluk.

Senaryo	Kesim:No	Tutarlılık			Anımsama			F1 skoru			Etiketler			Doğruluk (%)	
		NC	MC	HC	NC	MC	HC	NC	MC	HC	NC	MC	HC	DMLP	CNN
S1	1-2-3-4-5-6-7	0.98	1.00	1.00	1.00	0.93	1.00	0.99	0.96	1.00	173	41	73	60.27	98.95
S1-WCP		1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	173	41	73	67.60
S2	7-14-10-11- 22-23	0.99	1.00	1.00	1.00	1.00	0.98	1.00	1.00	0.99	173	41	42	67.57	99.61
S2-WCP		1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	173	41	42	83.98
S3	7-14-21-15- 16-24-25	0.87	1.00	1.00	1.00	1.00	0.59	0.93	1.00	0.74	173	41	63	62.45	90.61
S3-WCP		1.00	1.00	0.98	0.99	1.00	1.00	1.00	1.00	0.99	1.00	173	41	63	77.61

4.3. Model Performansının Literatürdeki Çalışmalar ile Karşılaştırılması

Literatürde, tez kapsamında yapılan CNN metodu ile tırlama titreşimlerinin tespiti üzerine yapılmış 3 çalışma bulunmaktadır. Bunlardan bir tanesi tez çalışmasından kapsamında üretilmiştir [3]. Tran vd. freze işlemleri esnasında, tezgaha bağlı tabla tipi bir dinamometre kullanarak titreşim verilerini toplamışlardır. Yaptıkları çalışmada, geliştirdikleri CNN modeli %92'nin üzerinde oldukça yüksek bir başarıyla tırlama titreşimlerini tahmin etmektedir [55]. Bir diğer taraftan, yaptıkları çalışmada AI modelini geliştirirken test ve eğitim verilerini karıştırarak bir veri seti hazırlamışlardır. Modelin test edilecek kesimlere ait verilerden parçalar görmesi mümkündür. Yani modelin test ve eğitim verileri arasında sızıntı olabilir. Zhu vd. benzer bir AI modeli kullanarak yine freze tezgahları üzerine ince cidarlı parçalarla çalışmışlardır [56]. Her kesimden sonra iş parçalarının yüzeyleri fotoğraflanmıştır. Bu fotoğraflar etiketlenerek bir CNN modeline verilmiş ve model tırlamanın olduğu kesimleri oldukça yüksek doğrulukla bilebilmiştir, ancak kamera kullanımının gerekmesinden dolayı endüstriyel uygulamalarda bu yöntemin kendine yer bulması daha zor olacaktır. Yine aynı çalışmada bir önce bahsi geçen çalışmada da olduğu gibi eğitim ve test verileri toplu halde karıştırılarak kullanılmıştır. Bir diğer yandan bu tez çalışmasında, geliştirilen CNN modelinin eğitim ve test verileri birbirinden tamamen ayrı tutulmuştur. Tırlama saptanan kesimlere ait veri parçaları birbirlerinden ayrılmamıştır. Diğer çalışmalara göre çok daha zor olan yöntem ile yüksek başarı sağlamak için, CNN modelinin mimarisi kesme parametrelerini de girdi olarak kullanacak şekilde geliştirilmiştir. Tüm bunların yanında, algılayıcı olarak tezgah üzerine bağlanması en kolay sensörlerden biri olan ivmeölçer kullanılmıştır. Bu çalışmanın diğer yayınlar ile detaylı karşılaştırması Çizelge 4.2'de verilmiştir.

Çizelge 4.2: Geliştirilen CNN ile tırlama tespit yönteminin literatürdeki diğer çalışmalar ile karşılaştırması.

Kaynak	Operasyon	Devir- Derinlik	Algılayıcı	Ön işlem	Girdi verileri	Sınıflandırma	Doğruluk
[3]	Omuz Freze	6250-15500rpm/ 2-4mm	İvme ölçer	Dalgacık dönüşümü	Karışmamış dalgacıklar ve kesme parametreleri	Çok sınıflı	%99.88
[55]	Kanal Freze	2250-6000/0.4-2mm	Dinamometre	Dalgacık dönüşümü	Karışık dalgacıklar	Çok sınıflı	%99.12
[56]	Omuz freze İnce cidar	Belirtilmemiş	Kamera	Boyut küçültme	İş parçası görüntüleri	İkili	%98.26

5. SONUÇLAR

Makine öğrenimi yöntemlerini kullanarak tırlama tespiti üzerine yapılan önceki araştırmalar, sınıflandırmaya uymak için önemli özellik mühendisliği gerektirir. CNN, sinyal özellik seçimini ve etkinleştirmeyi kendisi yaptığı için büyük bir avantaja sahiptir, dolayısıyla sinyal işleme mühendisliği aşamasını ortadan kaldırır. Ön işlem için, CWT mükemmel bir iş çıkarır ve sistemin modal frekansları etrafındaki kritik tırlama bilgilerini ortaya koyar. Bu çalışmada, CNN ve CWT kullanılarak yeni bir tırlama algılama yöntemi geliştirilmiştir. Sistemin SLD'si, Fourier genişletme teorisi kullanılarak oluşturulmuş ve deneylerin yapılacağı kesme parametreleri, sistemin kararlılık haritasına göre seçilmiştir. CNN algoritmasının eğitim aşamasında, endüstriyel üretim ortamlarını daha gerçekçi bir şekilde temsil edebilmek için, daha önceki çalışmalara benzer şekilde eğitim ve test verilerinde herhangi bir değişiklik yapılmadı. Önerilen tırlama tespit yaklaşımı, CNN algoritmasının, tam test ve eğitim verisi ayırma ile bile, yüksek algılama doğruluğuna (%90.61-%99.61) ulaşabildiğini gösterdi ve geliştirilen algoritmanın, test olarak sunulan tamamen yeni verilerle tırlamayı tespit edebildiğini garanti etti. Ayrıca önerilen yöntem, kesme parametrelerinin CWT ile kullanılmasının CNN algoritmasının performansını %100'e kadar artırdığını kanıtlamıştır. Bu çalışmadan aşağıdaki kritik sonuçlar çıkarılmıştır.

1) Tırlama etiketleri söz konusu olduğunda, kesme parametrelerinin ideal dağılımını belirlemede yardımcı olan kanıtlanmış model tabanlı yöntemle oluşturulan SLD kullanılmıştır. Sistemin model parametreleri, dalgacıklar üzerindeki zengin içerikli bantların tanınmasına ve bunları kesme frekansları ve diğer harmoniklerden ayırt etmesine yardımcı olmaktadır.

2) Titreşim sinyalleri, özellik mühendisliği için herhangi bir çaba harcamadan CWT kullanılarak işlenmiştir. Ortaya çıkan dalgacıklar hem zaman hem de frekans alanlarındaki tırlama hakkında temel bilgileri içerir. Dalgacıklar CNN algoritması için bir girdi olarak kullanılmıştır. En önemlisi, eğitim ve test veri seti hazırlanırken, önceki araştırmalara göre daha sağlam bir yaklaşım seçilmiştir. Her kesim verisinden 100 ms'lik parçalar oluşturulduktan sonra, eğitim ve test kesimi verileri birbiriyle karıştırılmamıştır ve eğitim kesimlerinin test kesimlerinden tamamen ayrıldığını garanti altına alınmıştır. Üretim sırasında herhangi bir rastgele kesme parametresinden

alınan titreşim verilerinin eğitimde olmayacağını garantilediğinden, bu yöntemin endüstriyel alanlarda yüksek bir uyarlanabilirlik potansiyeline sahip olduğunu kanıtlamaktadır.

3) CNN algoritmasının performansı, her kesim ayrı ayrı test verisi olarak seçip, kalan tüm kesimlerin eğitim verisi olarak kullanıldığı bir incelemenden geçirildi (bölüm 4.1). Her bir saptamanın karşılık gelen kayıp değerleri, karşılaştırma için bir kabarcık haritası olarak düzenlenmiştir. Bu sayede modelin en çok zorlanacağı şartlar belirlenerek model bu bölgelerde test edilmiştir. Ayrıca yapılan bu incelemenin sonucunda yaklaşık 10000 dd gibi beklenmedik bir yüksek stabilite bölgesinde CNN algoritmasının maksimum kayıp değerlerine sahip olduğu görülmüştür. Bununla birlikte, bu bölgeden SLD kullanılarak eğitim setine yeterince dahil edildiğinde, %90'ın üzerinde bir doğruluk elde edilmiştir.

4) CNN algoritmasının farklı koşullar altında performansını tam olarak anlamak için, farklı etiket dağılımları ve farklı veriler içeren farklı senaryolar gerçekleştirilmiştir. Tam bağlı katmanlar değiştirilerek kesme derinliği ve iş mili hızı gibi kesme parametrelerin CNN algoritmasına dalgacıklar ile beraber girdi olarak sokulması sağlanmıştır. CNN algoritmasına bu tür parametrelerin eklenmesi, her durumda test doğruluğunu arttırdığı gibi belirli durumlarda da test doğruluğunu %100'e kadar artırmıştır.

Geliştirilen tırlama algılama yaklaşımı, titreşim verilerinden elde edilen CWT ve kesme parametrelerini kullanarak yoğun görüntü özellikleri ile skaler değerleri birleştirildiğinde, tez kapsamında geliştirilen CNN yönteminin başarısını gösterir. Bu aynı zamanda operasyon sırasında operatöre sunulan tahmini mod parametrelerini, malzeme özelliklerini ve diğer araçla ilgili verileri eklemek için mükemmel bir fırsat sunar. Bir diğer deyişle geliştirilen model, doğrudan başka takım tezgahlarından elde edilen verilerin içerisinde tırlama tespiti yapılmasına imkan sağlamaktadır.

6. KAYNAKLAR

- [1] Arrazola PJ, Özel T, Umbrello D, Davies M, Jawahir IS. Recent advances in modelling of metal machining processes. *CIRP Ann - Manuf Technol.* 2013;62(2):695–718.
- [2] Quintana G, Ciurana J. Chatter in machining processes: A review. *Int J Mach Tools Manuf* [Internet]. 2011;51(5):363–76. Available from: <http://dx.doi.org/10.1016/j.ijmachtools.2011.01.001>
- [3] Sener B, Gudelek MU, Ozbayoglu AM, Unver HO. A novel chatter detection method for milling using deep convolution neural networks. *Meas J Int Meas Confed* [Internet]. 2021;182:109689. Available from: <https://doi.org/10.1016/j.measurement.2021.109689>
- [4] Dutta S, Pal SK, Sen R. Tool Condition Monitoring in Turning by Applying Machine Vision. 2016;138(May):1–17.
- [5] Teti R, Jemielniak K, O'Donnell G, Dornfeld D. Advanced monitoring of machining operations. *CIRP Ann - Manuf Technol.* 2010;59(2):717–39.
- [6] Wiercigroch M, Krivtsov AM. Frictional chatter in orthogonal metal cutting. *Philos Trans R Soc A Math Phys Eng Sci.* 2001;359(1781):713–38.
- [7] Wiercigroch M, Budak E. Sources of nonlinearities, chatter generation and suppression in metal cutting. *Philos Trans R Soc A Math Phys Eng Sci.* 2001;359(1781):663–93.
- [8] Tekeli A, Budak E. Maximization of chatter-free material removal rate in end milling using analytical methods. *Mach Sci Technol.* 2005;9(2):147–67.
- [9] Altıntaş Y, Budak E. Analytical Prediction of Stability Lobes in Milling. *CIRP Ann - Manuf Technol.* 1995;44(1):357–62.
- [10] YUE C, GAO H, LIU X, LIANG SY, WANG L. A review of chatter vibration research in milling. *Chinese J Aeronaut* [Internet]. 2019;32(2):215–42. Available from: <https://doi.org/10.1016/j.cja.2018.11.007>
- [11] Le Lan J-V, Marty A, Debongnie J-F. A stability diagram computation method for milling adapted to automotive industry [Internet]. *CIRP - High performance cutting.* 2006. Available from: <http://hdl.handle.net/2268/13781>

- [12] Altintas Y, Weck M. Chatter stability of metal cutting and grinding. *CIRP Ann - Manuf Technol.* 2004;53(2):619–42.
- [13] Zhang Z, Li H, Meng G, Tu X, Cheng C. Chatter detection in milling process based on the energy entropy of VMD and WPD. *Int J Mach Tools Manuf* [Internet]. 2016;108:106–12. Available from: <http://dx.doi.org/10.1016/j.ijmachtools.2016.06.002>
- [14] Delio T, Tlustý J, Smith S. Use of audio signals for chatter detection and control. *J Manuf Sci Eng Trans ASME.* 1992;114(2):146–57.
- [15] Altintas Y, Chan PK. In-process detection and suppression of chatter in milling. *Int J Mach Tools Manuf.* 1992;32(3):329–47.
- [16] Schmitz TL, Medicus K, Dutterer B. Exploring once-per-revolution audio signal variance as a chatter indicator. *Mach Sci Technol.* 2002;6(2):215–33.
- [17] Sun H, Zhang X, Wang J. Online machining chatter forecast based on improved local mean decomposition. *Int J Adv Manuf Technol.* 2016;84(5–8):1045–56.
- [18] Cao H, Zhou K, Chen X. Chatter identification in end milling process based on EEMD and nonlinear dimensionless indicators. *Int J Mach Tools Manuf* [Internet]. 2015;92:52–9. Available from: <http://dx.doi.org/10.1016/j.ijmachtools.2015.03.002>
- [19] Soliman E, Ismail F. Chatter suppression by adaptive speed modulation. *Int J Mach Tools Manuf.* 1997;37(3):355–69.
- [20] Samanta B. Surface roughness prediction in machining using soft computing. *Int J Comput Integr Manuf.* 2009;22(3):257–66.
- [21] Kuljanic E, Totis G, Sortino M. Development of an intelligent multisensor chatter detection system in milling. *Mech Syst Signal Process.* 2009;23(5):1704–18.
- [22] Yao Z, Mei D, Chen Z. On-line chatter detection and identification based on wavelet and support vector machine. *J Mater Process Technol.* 2010;210(5):713–9.
- [23] Lamraoui M, Barakat M, Thomas M, Badaoui M El. Chatter detection in milling machines by neural network classification and feature selection. *JVC/Journal*

- Vib Control. 2015;21(7):1251–66.
- [24] Sener B, Serin G, Gudelek MU, Murat Ozbayoglu A, Unver HO. Intelligent Chatter Detection in Milling using Vibration Data Features and Deep Multi-Layer Perceptron. Proc - 2020 IEEE Int Conf Big Data, Big Data 2020. 2020;4759–68.
- [25] Chen GS, Zheng QZ. Online chatter detection of the end milling based on wavelet packet transform and support vector machine recursive feature elimination. Int J Adv Manuf Technol. 2018;95(1–4):775–84.
- [26] Chen Y, Li H, Jing X, Hou L, Bu X. Intelligent chatter detection using image features and support vector machine. Int J Adv Manuf Technol. 2019;102(5–8):1433–42.
- [27] Tlustý J, Ismail F. Special Aspects of Chatter in Milling. Am Soc Mech Eng. 1981;105(81).
- [28] Tlustý J, Smith S, Zamudio C. New NC Routines for Quality in Milling. CIRP Ann - Manuf Technol. 1990;39(1):517–21.
- [29] Weck M, Altintas Y, Beer C. CAD assisted chatter-free NC tool path generation in milling. Int J Mach Tools Manuf. 1994;34(6):879–91.
- [30] Budak E, Altıntaş Y. Analytical prediction of chatter stability in milling—part I: General formulation. J Dyn Syst Meas Control Trans ASME. 1998;120(1):22–30.
- [31] Rioul O, Duhamel P. Fast Algorithms for Discrete and Continuous Wavelet Transforms. IEEE Trans Inf Theory. 1992;38(2):569–86.
- [32] Berger BS, Minis I, Harley J, Rokni M, Papadopoulos M. Wavelet based cutting state identification. J Sound Vib. 1998;213(5):813–27.
- [33] Ingrid Daubechies. Ten Lectures on Wavelets. 1992.
- [34] Techniques WA. WAVELET ANALİZ TEKNİĞİ VE UYGULAMA. 2017;(1):42–56.
- [35] Addison PS. Introduction to redundancy rules: The continuous wavelet transform comes of age. Philos Trans R Soc A Math Phys Eng Sci. 2018;376(2126).

- [36] Dornfeld DA, DeVries MF. Neural Network Sensor Fusion for Tool Condition Monitoring. *CIRP Ann - Manuf Technol.* 1990;39(1):101–5.
- [37] Park KS, Kim SH. Artificial intelligence approaches to determination of CNC machining parameters in manufacturing : a review. 1998;12:127–34.
- [38] Abellan-Nebot JV, Romero Subirón F. A review of machining monitoring systems based on artificial intelligence process models. *Int J Adv Manuf Technol.* 2010;47(1–4):237–57.
- [39] Nasir V. A review on deep learning in machining and tool monitoring : methods , opportunities , and challenges. 2021;
- [40] Bengio Y, Courville A, Vincent P. Representation Learning : A Review and New Perspectives. 2013;35(8):1798–828.
- [41] Miotto R, Wang F, Wang S, Jiang X, Dudley JT. Deep learning for healthcare : review , opportunities and challenges. 2017;(February):1–11.
- [42] Lecun Y, Bengio Y, Hinton G. Deep learning. *Nature.* 2015;521(7553):436–44.
- [43] Serin G, Sener B, Ozbayoglu AM, Unver HO. Review of tool condition monitoring in machining and opportunities for deep learning. 2020;
- [44] Pitts WSM& W. A logical calculus of the ideas immanent in nervous activity. 1943;5:115–33.
- [45] Pitts W. I. Introduction and Definitions. 1942;4:121–9.
- [46] Güdelek MU. Zaman Serisi Analizi Ve Tahmini: Derin Öğrenme Yaklaşımı. TOBB Ekonomi ve Tetknoloji Üniversitesi; 2019.
- [47] Ugur Gudelek M, Arda Boluk S, Murat Ozbayoglu A. A deep learning based stock trading model with 2-D CNN trend detection. 2017 IEEE Symp Ser Comput Intell SSCI 2017 - Proc. 2018;2018-Janua:1–8.
- [48] Fukushima K. *Biological Cybernetics.* 1980;202.
- [49] Waibel A, Hanazawa T, Hinton G, Shikano K LK. Phoneme Recognition Using Time-Delay Neural Networks I”. 1989;31(3):328–39.
- [50] LeCun Y, Boser B, Denker JS, Henderson D, Howard RE, Hubbard W, et al. Backpropagation Applied to Handwritten Zip Code Recognition. *Neural*

- Comput. 1989;1(4):541–51.
- [51] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton. ImageNet Classification with Deep Convolutional Neural Networks. 2012; Available from: <https://proceedings.neurips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>
- [52] Cao H, Zhou K, Chen X, Zhang X. Early chatter detection in end milling based on multi-feature fusion and 3σ criterion. *Int J Adv Manuf Technol.* 2017;92(9–12):4387–97.
- [53] Oleaga I, Pardo C, Zulaika JJ, Bustillo A. A machine-learning based solution for chatter prediction in heavy-duty milling machines. *Meas J Int Meas Confed [Internet].* 2018;128(May):34–44. Available from: <https://doi.org/10.1016/j.measurement.2018.06.028>
- [54] Fu Y, Zhang Y, Gao Y, Gao H, Mao T, Zhou H, et al. Machining vibration states monitoring based on image representation using convolutional neural networks. *Eng Appl Artif Intell [Internet].* 2017;65(July):240–51. Available from: <http://dx.doi.org/10.1016/j.engappai.2017.07.024>
- [55] Tran MQ, Liu MK, Tran QV. Milling chatter detection using scalogram and deep convolutional neural network. *Int J Adv Manuf Technol.* 2020;107(3–4):1505–16.
- [56] Zhu W, Zhuang J, Guo B, Teng W, Wu F. An optimized convolutional neural network for chatter detection in the milling of thin-walled parts. *Int J Adv Manuf Technol.* 2020;106(9–10):3881–95.
- [57] Schwarz BJ, Richardson MH. Método de análisis modal experimental. 1999;1–12. Available from: <http://papers.vibetech.com/Paper28-ExperimentalModalAnalysis.pdf>
- [58] Smith S, Tlustý J. Overview of modeling and simulation of the milling process. *J Eng Ind.* 1991;113(2):169–75.
- [59] Cao H, Lei Y, He Z. Chatter identification in end milling process using wavelet packets and Hilbert-Huang transform. *Int J Mach Tools Manuf [Internet].* 2013;69:11–9. Available from: <http://dx.doi.org/10.1016/j.ijmachtools.2013.02.007>

- [60] Lu W, Xiao R, Yang J, Li H, Zhang W. Data mining-aided materials discovery and optimization. *J Mater* [Internet]. 2017;3(3):191–201. Available from: <http://dx.doi.org/10.1016/j.jmat.2017.08.003>



