

T.C.
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**SİNYAL İŞLEME VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ
İLE DÖNEN MAKİNELERDE TİTREŞİM SİNYALLERİNDEN
ARIZA ANALİZİ VE TESPİTİ**

YÜKSEK LİSANS TEZİ

HÜSEYİN CANBAZ

BOLU, AĞUSTOS - 2019

T.C.
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI



SİNYAL İŞLEME VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ
İLE DÖNEN MAKİNELERDE TİTREŞİM SİNYALLERİNDEN
ARIZA ANALİZİ VE TESPİTİ

YÜKSEK LİSANS TEZİ

HÜSEYİN CANBAZ

BOLU, AĞUSTOS - 2019

KABUL VE ONAY SAYFASI

Hüseyin CANBAZ tarafından hazırlanan “Sinyal İşleme ve Makine Öğrenmesi Yöntemleri İle Dönen Makinelerde Titreşim Sinyallerinden Arıza Analizi ve Tespiti” adlı tez çalışması ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI'NDA 8.07.2019 tarihinde savunularak Bolu Abant İzzet Baysal Üniversitesi Fen Bilimleri Enstitüsü YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Danışman
Doç. Dr. Kemal POLAT
Bolu Abant İzzet Baysal Üniversitesi

Üye
Dr Öğr. Üyesi Nihat DALDAL
Bolu Abant İzzet Baysal Üniversitesi

Üye
Dr Öğr. Üyesi Ahmet Hayrettin YÜZER
Karabük Üniversitesi

İmza

.....
.....
.....

Prof. Dr. Ömer ÖZYURT

.....
.....

Fen Bilimleri Enstitüsü Müdürü



Aileme,

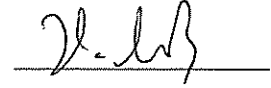
ETİK BEYAN

Abant İzzet Baysal Üniversitesi, Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Hüseyin CANBAZ



ÖZET

**SİNYAL İŞLEME VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE
DÖNEN MAKİNELERDE TİTREŞİM SİNYALLERİNDEN ARIZA
ANALİZİ VE TESPİTİ
YÜKSEK LİSANS TEZİ
HÜSEYİN CANBAZ
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
(TEZ DANIŞMANI: DOÇ. DR. KEMAL POLAT)**

BOLU, AĞUSTOS - 2019

Bu tez çalışmasında, endüstride sıklıkla kullanılan CNC makinesinin matkap ucunda meydana gelen hataların tespitine yönelik çalışmalar gerçekleştirilmiştir. Üretimde kullanılan her makine için zamanla arızalanma kaçınılmazdır. Arızaları meydana gelmeden önce tahmin edebilmek hem insan gücü kaybının hem de yüksek miktarlardaki onarım maliyetinin oluşmasına engel olur. Bu sebeple, makinelerde oluşan hataları analiz edebilmek uzun yıllardır uygulanan popüler bir konudur.

Daha önce yapılan çalışmalar incelendiğinde, makinelerin çalışma koşullarında alınan gerilim, akım, sıcaklık ve titreşim gibi nicelikler kullanılmaktadır. Bu çalışmada, CNC makinesinin çalışması esnasında alınan titreşim sinyallerini içeren veri kümesi kullanılmıştır. Hataları teşhis edebilmek için, ham titreşim sinyallerinden özellikler çıkarılmıştır. Özellik çıkarma işlemi, büyük miktarda veri içerisinden değerli olan az miktardaki veriyi elde etmeyi sağlamaktadır. Bu bağlamda zaman alanı, frekans alanı, zaman-frekans alanı ve bu alanların birleşimi olmak üzere 4 alanda özellikler elde edilmiştir. Özellik çıkarma işleminden sonra, normalizasyon işlemi uygulanmıştır. Bu şekilde farklı değerlere sahip özelliklerin aynı anda verimli bir şekilde işlenebilmesi sağlanmıştır. Normalizasyon işleminden sonra, Uzun-Kısa Dönem Hafıza yapısı ve çeşitli derin öğrenme katmanları kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.

Yapılan işlemler sonucunda %99,53 doğruluk oranı elde edilmiştir. Alınan doğruluk oranının karşılaştırmasını yapabilmek için, bu alanda çok tercih edilen Destek Vektör Makineleri kullanılmıştır.

Bu çalışma ile, bu alanda daha önce kullanılmayan Uzun-Kısa Dönem Hafıza yapısı ile dönen makinelerde hata analizi yapılabileceği gösterilmektedir. Ek olarak, oluşturulan yapay sinir ağına farklı katmanlar eklemenin sonuca etkileri gösterilmektedir.

ANAHTAR KELİMELER: UKDH, TSA, Dönen makineler, Hata teşhisi, Çok katmanlı yapay sinir ağları

ABSTRACT

FAULT ANALYSIS AND DETECTION FROM VIBRATION SIGNALS IN ROTATING MACHINES WITH SIGNAL PROCESSING AND MACHINE LEARNING METHODS

MSC THESIS

HÜSEYİN CANBAZ

BOLU ABANT IZZET BAYSAL UNIVERSITY GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

**DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
(SUPERVISOR: ASSOC. PROF. KEMAL POLAT)**

BOLU, AUGUST 2019

In this thesis, studies were carried out to determine the faults occurring at the drill bit end of the CNC machine, which is frequently used in the industry. Failure is inevitable for each machine used in production. Prediction of failures before they occur prevents both loss of manpower and high cost of repair. For this reason, analyzing faults in machines is a popular subject that has been applied for many years.

When the previous studies are examined, the quantities such as voltage, current, temperature and vibration taken under the working conditions of the machines are used. In this study, a dataset containing the vibration signals measured during the operation of the CNC machine is used. In order to diagnose faults, the features have been extracted of the raw vibration signals. The feature extraction process allows obtaining a small amount of data which is valuable from a large amount of data. In this context, features were obtained in 4 areas which are: time domain, frequency domain, time-frequency domain and the combination of these. After feature extraction, normalization was performed. In this way, the features with different values can be processed efficiently at the same time. After the normalization process, the Long-Short Term Memory structure and various deep learning layers were realized.

As a result of the transactions 99,53% accuracy rate was obtained. In order to compare the obtained accuracy rate Support Vector Machines were used because of Support Vector Machines are frequently used in this area.

In this study, it is shown that fault analysis can be performed on machines with Long-Short Term Memory structure which is not so used in this field. In addition, the effects of adding different layers to the generated artificial neural network are shown.

KEYWORDS: LSTM, RNN, Rotating machines, Fault diagnosis, Multilayer artificial neural networks

İÇİNDEKİLER

Sayfa

ÖZET.....	v
ABSTRACT	vi
İÇİNDEKİLER	vii
ŞEKİL LİSTESİ.....	ix
ÇİZELGE LİSTESİ.....	x
KISALTMA VE SEMBOLLER LİSTESİ	xii
TEŞEKKÜR	xiii
1. GİRİŞ.....	1
1.1 Titreşim Tabanlı Hata Analizi ile İlgili Literatür Araştırması	3
1.2 Çeşitli YSA Yöntemleri Kullanılarak Yapılan Hata Analizi Çalışmaları ile İlgili Literatür Araştırması.....	4
1.3 UKDH ile İlgili Literatür Araştırması.....	5
2. YAPAY SİNİR AĞLARI.....	7
2.1 İleri Beslemeli Yapay Sinir Ağı.....	9
2.2 Geri Beslemeli Yapay Sinir Ağı	10
2.3 Derin Öğrenme.....	11
2.3.1 Toplama (Pooling) Katmanı	11
2.3.2 Rectified Linear Unit (ReLU) Katmanı	12
2.3.3 Tamamen Bağlı Katman	12
2.3.4 Kayıp Katmanı	13
3. TEKRAR EDEN SİNİR AĞLARI.....	14
4. UZUN KISA DÖNEM HAFIZA	16
5. MATERYAL.....	18
5.1 Veri Kümesi	18
5.2 Deeplearning4j Kütüphanesi.....	22
6. YÖNTEM.....	25
6.1 Veri Sayısının Kademeli Olarak Artırılması.....	26
6.2 Özellik Çıkarma	27
6.2.1 Zaman Alanı Özellikleri	27
6.2.2 Frekans Alanı Özellikleri.....	28
6.2.3 Zaman-Frekans Alanı Özellikleri	29
6.3 Normalizasyon	29
6.4 Çok Katmanlı UKDH Yapılarını Oluşturma	30
6.5 Sınıflandırma İşlemi İçin Kullanılan Veri Bölütleme Yöntemleri	30
6.5.1 K Fold Cross Validation Yöntemi	30
6.5.2 Hold-Out Yöntemi	31
7. DENEYSEL SONUÇLAR.....	33
7.1 Zaman Alanı Özellikleri Sonuçları	34

7.2	Frekans Alanı Özellikleri Sonuçları.....	38
7.3	Zaman-Frekans Alanı Özellikleri Sonuçları	42
7.4	Bütün Özellikler ile Elde Edilen Sonuçlar.....	46
8.	SONUÇ VE ÖNERİLER	51
9.	KAYNAKLAR.....	54
10.	EKLER.....	64
EK A	64
11.	ÖZGEÇMİŞ.....	67



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Biyolojik sinir hücresi yapısı.	8
Şekil 2.2. Yapay sinir hücresi yapısı.....	8
Şekil 2.3. İleri beslemeli yapay sinir ağı.....	10
Şekil 2.4. Geri beslemeli yapay sinir ağı örneği.	11
Şekil 2.5. Maksimum toplama işlemi örneği.	12
Şekil 3.1. Tekrar eden sinir ağlarının çalışma prensibi.....	14
Şekil 3.2. Tekrar eden sinir ağlarının örnek yapısı.	15
Şekil 4.1. Basit TSA yapısı.	16
Şekil 4.2. Tekrar eden 4 adet aktivasyon fonksiyonlu UKDH yapısı.....	17
Şekil 5.1. EMCO concept mill 105 (Yang ve Xu, 2008).....	18
Şekil 5.2. Hata çeşitleri (a) körleşme (b) yan tarafın aşınması (c) dış köşe aşınması (Kanai ve Kenda, 1978).	19
Şekil 5.3. Hatalı durumların gerçek resimleri (a) körleşme (b) yan taraf aşınması (c) dış köşe aşınması (Kumar vd., 2014).....	20
Şekil 5.4. Matkap ucunun körleşmesi hatasının titreşim sinyali.....	21
Şekil 5.5. Matkap ucunun yan tarafının aşınması hatasının titreşim sinyali....	21
Şekil 5.6. Matkap ucunun dış köşesinin aşınması hatasının titreşim sinyali. ...	21
Şekil 5.7. Normal durumun titreşim sinyali.	22
Şekil 5.8. Weka programında deeplearning4j kütüphanesinin arayüzü (Lang vd., 2019).....	23
Şekil 5.9. Deeplearning4j kütüphanesinde sunulan katmanlar (Lang vd., 2019).....	24
Şekil 6.1. Oluşturulan sistemin blok diyagramı.....	25
Şekil 6.2. Veri sayısını artırma işleminin gösterimi.	26
Şekil 6.3. K fold cross validation gösterimi.....	31
Şekil 6.4. Hold out gösterimi (a) birinci yöntem (b) ikinci yöntem.	32

ÇİZELGE LİSTESİ

Sayfa

Çizelge 7.1.	Zaman alanında birinci yöntem kullanılarak elde edilen doğruluk oranları (%).	34
Çizelge 7.2.	Zaman alanında ikinci yöntem kullanılarak elde edilen doğruluk oranları (%).	35
Çizelge 7.3.	Zaman alanında üçüncü yöntem kullanılarak elde edilen doğruluk oranları (%).	36
Çizelge 7.4.	Zaman alanında DVM yöntemi kullanılarak elde edilen doğruluk oranları (%).	37
Çizelge 7.5.	Zaman alanında elde edilen en iyi sonuçların hata matrisleri.	37
Çizelge 7.6.	Zaman alanında elde edilen en iyi sonuçların ortalama değerleri.	37
Çizelge 7.7.	Frekans alanında birinci yöntem kullanılarak elde edilen doğruluk oranları (%).	38
Çizelge 7.8.	Frekans alanında ikinci yöntem kullanılarak elde edilen doğruluk oranları (%).	39
Çizelge 7.9.	Frekans alanında üçüncü yöntem kullanılarak elde edilen doğruluk oranları (%).	40
Çizelge 7.10.	Frekans alanında DVM yöntemi kullanılarak elde edilen doğruluk oranları (%).	41
Çizelge 7.11.	Frekans alanında elde edilen en iyi sonuçların hata matrisleri.	41
Çizelge 7.12.	Frekans alanında elde edilen en iyi sonuçların ortalama değerleri.	41
Çizelge 7.13.	Zaman-frekans alanında birinci yöntem kullanılarak elde edilen doğruluk oranları (%).	42
Çizelge 7.14.	Zaman-frekans alanında ikinci yöntem kullanılarak elde edilen doğruluk oranları (%).	43
Çizelge 7.15.	Zaman-frekans alanında üçüncü yöntem kullanılarak elde edilen doğruluk oranları (%).	44
Çizelge 7.16.	Zaman-Frekans alanında DVM kullanılarak elde edilen doğruluk oranları (%).	45
Çizelge 7.17.	Zaman-frekans alanında elde edilen en iyi sonuçların hata matrisleri.	45
Çizelge 7.18.	Zaman-frekans alanında elde edilen en iyi sonuçların ortalama değerleri.	45
Çizelge 7.19.	Tüm özelliklerden birinci yöntem kullanılarak elde edilen doğruluk oranları (%).	46
Çizelge 7.20.	Tüm özelliklerden ikinci yöntem kullanılarak elde edilen doğruluk oranları (%).	47
Çizelge 7.21.	Tüm özelliklerden üçüncü yöntem kullanılarak elde edilen doğruluk oranları (%).	48
Çizelge 7.22.	Tüm özelliklerden DVM yöntemi kullanılarak elde edilen doğruluk oranları (%).	49
Çizelge 7.23.	Tüm özelliklerde elde edilen en iyi sonuçların hata matrisleri.	49
Çizelge 7.24.	Tüm özelliklerde elde edilen en iyi sonuçların ortalama değerleri.	49

Çizelge 7.25. Sınıflandırma işlemi için ölçülen ortalama işlem süreleri (saniye).....	50
-------------------------------------------------------------------------------------------------	----



KISALTMA VE SEMBOLLER LİSTESİ

AKD	: Ayrık kosinüs dönüşümü
DBM	: Derin Boltzmann makinesi
DÖ	: Derin öğrenme
DVM	: Destek vektör makinesi
ESA	: Evrişimli sinir ağları
HFD	: Hızlı fourier dönüşümü
HP	: Horse power
KBM	: Kısıtlanmış Boltzmann makinesi
MÇSD	: Modüler çok seviyeli dönüştürücü
MDD	: Morlet dalgacık dönüşümü
MÖ	: Makine öğrenmesi
OK	: Otomatik kodlayıcı
RO	: Rastgele orman
TSA	: Tekrar eden sinir ağları
UKDH	: Uzun-kısa dönem hafıza
YSA	: Yapay sinir ağları
YZ	: Yapay zeka

TEŐEKKÖR

Bu alıőmada, dnen makinelerde oluőan eőitli hataların teőhisi uygulanmıőtır. alıőma konusunun belirlenmesi ve hazırlanması srecinde kıymetli bilgi ve tecrbeleri ile beni ynlendiren deęerli hocam Do. Dr. Kemal POLAT'a en iten dileklerle teőekkr ederim. Eęitim-ęretim hayatım boyunca bilgilerini ve tecrbelerini benimle paylaőan deęerli hocalarıma ve her zaman benden desteklerini esirgemeyen aileme teőekkr ederim.



1. GİRİŞ

Teknoloji ve bilimdeki gelişmeler ile birlikte, modern endüstride kullanılan mekanik sistemler her zamankinden daha fonksiyonel ve daha karmaşık hale gelmiştir. Dönen makineler ise bu sistemin vazgeçilmez bir parçasıdır. Hemen hemen her alanda kullanılan dönen makinelerin arızalanması, veriminin düşmesi veya kısa bir süreliğine bile olsa duraksaması üretim sürecine çok ağır hasarlar verebilmektedir. Bu sebeple dönen makinelerde hata analizi, sistem tasarımı ve bakımında en önemli konulardan biridir.

Dönen makinelerde hata analizinin temelde 3 çeşit görevi vardır: (1) sistemin hatalı veya hatasız olup olmadığını teşhis etmek, (2) hatayı ve hatanın sebebini başlangıç aşamasında iken teşhis etmek, (3) hatanın hangi yönde ilerleyeceğini tahmin edebilmektir(Liu vd., 2018). Böylece, hata analizi temel olarak dönen makinelerin çalışma koşullarındaki problemlerin tanımlanması olarak düşünülebilir.

Literatürde yapılan çalışmalar incelendiğinde görülmektedir ki geçmiş zamanda yapılan çalışmaların çoğu sinyal işleme teknikleri kullanılarak yapılmıştır. Son yıllarda Makine Öğrenmesi (MÖ), Yapay Zekâ (YZ) ve Yapay Sinir Ağları (YSA) gibi daha güncel yöntemlerin yaygınlaşması bu alanda daha etkili çalışmalar yapmaya fırsat tanımıştır ve bu sayede daha kesin sonuçlar elde edebilmeyi mümkün hale getirmiştir.

Bu çalışmada, bilgisayarlı CNC makinesinin matkap ucundaki hatalı ve hatasız durumların teşhisine yönelik farklı yapılar test edilmiştir. Bu gibi çalışmalarda verileri elektrik elektronik laboratuvarında elde etmek veya daha önce elde edilmiş veriler üzerinde çalışmak mümkündür. Verma vd. (2015), yaptıkları çalışmada titreşim sinyallerinden hata analizi yapmak için veri kümesi oluşturmuşlardır. Bu çalışmada temel veri kaynağı olarak bu veri kümesi kullanılmaktadır. Bu veriler, güncel olarak endüstride kullanılan bir CNC cihazı ve matkap ucu içerdiği için sonuçlar gerçek koşullara oldukça uygundur.

Veri kümesi elde edilirken, matkap ucu metal levhayı delirken ve deldikten sonra olmak üzere iki aşamada titreşim sinyalleri ölçülmüştür. Titreşim sinyallerini elde etmek için PCB 63001 isimli tek eksenli akselerometre kullanılmıştır. Bu sensör aracılığı ile elde edilen analog veriler bilgisayar ortamına aktarılıp dijital veriye dönüştürülmüştür.

Bu veri kümesinde toplamda 3 adet hata durumu vardır. Bunlar sırasıyla; matkap ucunun körleşmesi, matkap ucunun yan tarafından aşınması ve matkap ucunun dış köşesinin aşınması şeklindedir. Bunlar sıklıkla karşılaşılan hata durumları olup bunlara ek olarak bir tane de normal durum verisi sunulmuştur. Bu durumların detaylı açıklamaları ilerleyen bölümlerde yapılmaktadır. Bu çalışmada çeşitli ön işleme yöntemleri kullanılmaktadır. Bu ön işleme yöntemleri sırasıyla; verilerin uygun uzunluklarda bölünmesi, karşılaştırma yapabilmek için veri sayısının kademeli olarak artırılması ve son olarak min-max ve z-score normalizasyon yöntemleri ile verilerin normalize edilmesi şeklindedir.

Verilerin işleme uygun hale getirilmesinden sonra özellik çıkarma işlemi uygulanmaktadır. Toplamda 21 tane özellik elde edilmektedir. Bu özellikler özellik çıkarma bölümünde açıklanmaktadır.

Bu işlemlerden sonra, çok katmanlı YSA yapıları oluşturularak sınıflandırma işlemi gerçekleştirilmektedir. Çok katmanlı YSA yapıları oluşturulurken Uzun-Kısa Dönem Hafıza (UKDH) yöntemi esas alınmıştır. Bu kapsamda 4 farklı çok katmanlı YSA işlemi ile birlikte bir adet Destek Vektör Makinesi (DVM) uygulanmaktadır. Toplamda yapılan 5 adet işlem ilerleyen bölümlerde detaylı olarak açıklanmaktadır. DVM yöntemi bu alanda yüksek doğruluk oranı sunması ile dikkat çeken bir yöntemdir. Bu yüksek doğruluk oranı sunma özelliği sebebiyle çok katmanlı YSA yapıları ile elde edilen sonuçlar bu yöntemle karşılaştırılmaktadır. Sonuç olarak gayet yüksek doğruluk oranlarına sahip algoritmalar geliştirilmiştir.

Farklı yöntemlerle yapılmış hata analizi çalışmalarına dair literatür araştırmaları ilerleyen alt bölümlerde gösterilmektedir.

1.1 Titreşim Tabanlı Hata Analizi ile İlgili Literatür Araştırması

Yapılan araştırmalar sonucunda, titreşim sinyalleri baz alınarak yapılan çeşitli hata analizi çalışmaları bu bölümde gösterilmektedir. Ayaz (2002), 5 HP gücündeki asenkron motorun rulmanında yapay olarak arıza oluşması sonucu elde edilen verileri kısa zaman fourier dönüşümü ve dalgacık analizi yöntemleri ile işlemiştir. Lin ve Zuo (2003), Morlet dalgacık dönüşümü tabanlı değişken dalgacık filtresi yöntemi kullanarak dişli kutusunun hata analizine yönelik çalışma yapmışlardır. Meltzer ve Dien (2004), sürekli dalgacık dönüşümü yöntemi ile dişli kutusundan farklı hızlarda ölçülen titreşim sinyallerinden hata analizi çalışması gerçekleştirmişlerdir. Fidan (2006), 1 HP gücündeki elektrik motorundan alınan çeşitli veriler aracılığıyla yapay olarak oluşturulan rulman arızasını dalgacık dönüşümü yöntemi kullanarak teşhis etmiştir. Dal vd. (2006), yapay sinir ağını eğitmek için makinelerdeki titreşim sinyallerinin değerlendirilmesine dayanan standartları içeren ISO-10816 tablosunu kullanarak çok katmanlı YSA yapısı oluşturup hata analizi çalışması yapmıştır. Aliustaoğlu vd. (2007), rulman arızaları üzerine, kullanılmamış rulman ile yapay olarak arıza oluşturulan rulman arasındaki farkı frekans analizi yöntemi ile göstermiştir. Bellini vd. (2008), indüksiyon motorundan alınan titreşim ve akım sinyallerini kullanarak sinyal işleme yöntemleri aracılığıyla hata analizi çalışması gerçekleştirmiştir. Rafiee vd. (2010), hata analizi gerçekleştirebilmek için otomatik özellik çıkarma yöntemini kullanmışlardır. Bu çalışmada titreşim sinyallerinden 4 adet özellik çıkarmışlardır. Henao vd. (2011), titreşim sinyallerini kullanarak demiryolu taşıma sisteminde kullanılan elektrik motorlarının hatalarına yönelik çalışma gerçekleştirmişlerdir. Villa vd. (2012), rüzgar türbini gibi günlük hayatta sıklıkla kullanılan dönen makinelerden, farklı hız ve yük koşulları altında alınan titreşim sinyallerini kullanarak, dengesizlik ve ayar bozukluğu hatalarını teşhis etmeye yönelik çalışma gerçekleştirmişlerdir. Yan vd. (2014), dönen makinelerde hata teşhisi için çok çeşitli dalgacık analizi teknikleri kullanmışlardır. Kullanılan teknikler arasında sürekli dalgacık dönüşümü, ayrık dalgacık dönüşümü, dalgacık paket dönüşümü ve ikinci nesil dalgacık dönüşümü gibi teknikler bulunmaktadır. Cerrada vd. (2015), dişli kutusundan ölçülen titreşim sinyallerinden hata analizi gerçekleştirmek için özellik seçme işlemi üzerine yoğunlaşan bir çalışma gerçekleştirmişlerdir. Bu çalışmada zaman, frekans ve zaman-frekans alanlarında en iyi özellikler seçilerek işlemler gerçekleştirilmiştir.

Ertekin vd. (2017), otomobillerde kullanılan disk fren sistemlerinden gelen seslerden matlab programı yardımı ile dalgacık tepeleri yaklaşımı kullanarak hatalı durumları hatasız durumdan ayırt etmiştir.

Literatür araştırmasından da görülebileceği gibi önceki yıllarda yapılan çalışmaların büyük kısmı klasik yöntemlere dayanmaktadır.

1.2 Çeşitli YSA Yöntemleri Kullanılarak Yapılan Hata Analizi Çalışmaları ile İlgili Literatür Araştırması

Saravanan vd. (2009), titreşim sinyallerini kullanarak, bulanık mantık ve karar ağacı yapıları aracılığı ile hata analizi çalışması gerçekleştirmişlerdir. Sakthivel vd. (2010), C4.5 karar ağacı algoritması yardımı ile santrifüj pompasının hatalarının analizine yönelik çalışma yapmışlardır. Pandya vd. (2012), rulman arızasının teşhisine yönelik, dalgacık paket dönüşümü ile özellik çıkarma işlemi gerçekleştirdikten sonra, çok katmanlı YSA ile sınıflandırma işlemi gerçekleştirmişlerdir. Seshadrinath vd. (2013), indüksiyon motor sürücülerinde meydana gelen çeşitli hatalar ile ilgili karmaşık dalgacıklar kullanmışlardır. Bu bağlamda ayırık dalgacık dönüşümü, DVM ve k en yakın komşu algoritmaları da karşılaştırma için kullanılmıştır. Jafari vd. (2014), içten yanmalı motorun supap arızasını teşhis etmek için Akustik Emisyon ve YSA yöntemlerini kullanmışlardır. Ali vd. (2015), titreşim sinyallerinden özellik çıkarma işlemi gerçekleştirdikten sonra, elde edilen özellikler ile YSA yapısının eğitimini gerçekleştirip rulman arızasını tahmin etmeye yönelik çalışma yapmışlardır. Janssens vd. (2016), dönen makinelerde Evrişimli Sinir Ağları (ESA) tabanlı hata analizi uygulaması gerçekleştirmiştir. Bu çalışmada servo motorun rulman arızası esnasında verdiği titreşim sinyalleri, veri ön işleme, özellik çıkarımı, özellik seçimi ve ESA modeli oluşturma aşamalarından geçirilerek 93.61 ve 87.25 doğruluk oranları elde edilmiştir. Liu vd. (2017), dönen makinelerde hata analizini gerçekleştirmek için k-en yakın komşu, naive bayes sınıflandırıcı, DVM, YSA ve Derin Öğrenme (DÖ) uygulamaları ile kapsamlı bir çalışma yapmıştır. Jing vd. (2017), gezegen diziliminde dişli düzenine sahip dişli kutusundan (şanzıman) alınan titreşim sinyalleri ile PHM topluluğu tarafından oluşturulmuş veri kümesi üzerinde çok katmanlı ESA yapısı ile 99.33 gibi yüksek bir doğruluk oranı elde etmişlerdir. Ayrıca bu çalışmada Rastgele Orman (RO), DVM ve tamamen bağlı YSA işlemleri de uygulanıp sonuçlar

karşılaştırılmıştır. Kiranyaz vd. (2018), Modüler Çok Seviyeli Dönüştürücü (MÇSD) cihazının arızasının teşhisine yönelik 1 boyutlu ESA yapısı kullanmışlardır. 2 boyutlu ESA temelde görüntü işleme uygulamaları için geliştirilmiş olduğundan vektör şeklinde olan veri kümelerinde kullanmak için verimli değildir. Bu sebeple bu çalışmada 2 boyutlu ESA yerine 1 boyutlu ESA kullanmayı tercih etmişlerdir. Rui vd. (2019), makine sağlığı konusunda ESA, Tekrar Eden Sinir Ağları (TSA), Otomatik Kodlayıcı (OK), Kısıtlanmış Boltzmann Makinesi (KBM) ve Derin Boltzmann Makinesi (DBM) yöntemlerini kullanarak bu sistemlerin avantajları ve dezavantajları üzerine karşılaştırmalı bir çalışma yapmıştır. Literatürde yapılan araştırmalarda görülmektedir ki; son yıllarda hata analizi ile ilgili çok çeşitli YSA yapıları kullanılmaktadır.

1.3 UKDH ile İlgili Literatür Araştırması

Wöllmer vd. (2010), ses ve mimik hareketlerinde duygu analizi yapmak için çift yönlü UKDH yapısını kullanmışlardır. Baccouche vd. (2011), insan hareketlerini teşhis etmek üzerine çalışma gerçekleştirmişlerdir. Bu çalışmada, otomatik olarak özellikleri elde edebilmek için 3 boyutlu ESA yapısı kullanılmış ve sınıflandırma işlemi için UKDH yapısı tercih edilmiştir. Sundermeyer vd. (2012), ingilizce ve Fransızca dillerinde otomatik olarak konuşma analizini gerçekleştirebilmek için UKDH yapısı kullanmışlardır. Bu çalışmada standart TSA yapısına göre %8 daha iyi sonuç elde edilmiştir. Breuel vd. (2013), makine çıktısı yazıların teşhisine yönelik çift yönlü UKDH yapısını kullanmışlardır. Fan vd. (2014), TSA ve çift yönlü UKDH yapılarını kullanarak rastgele iki kişi arasındaki konuşmayı anlık olarak yazıya çevirme üzerine çalışma yapmışlardır. Zhao vd. (2015), makine sağlığını izleme alanında çeşitli YSA yöntemlerini kullanarak karşılaştırmalı bir çalışma ortaya çıkarmıştır. De Bruin vd. (2016), demiryollarında meydana gelen bozuklukları teşhis edebilmek için UKDH yapısı kullanarak %99,7 doğruluk oranı elde etmeyi başarmışlardır. Aynı çalışmada, çıkan sonuç ESA ile karşılaştırılmış ve sonuçta UKDH yapısının daha iyi sonuç verdiği bulunmuştur. Choi vd. (2016), kalp durmasını gerçekleştirmeden önce tahmin edebilmek için UKDH yapısı kullanmıştır. Ayrıca bu çalışmada k en yakın komşu, DVM, çok katmanlı YSA ve TSA yapıları da kullanılmıştır. Zhao vd. (2016), makine sağlığını izleme alanında UKDH kullanan ilk dene çalışmayı gerçekleştirmişlerdir. Zhao vd. (2017), evrişimli çift yönlü UKDH

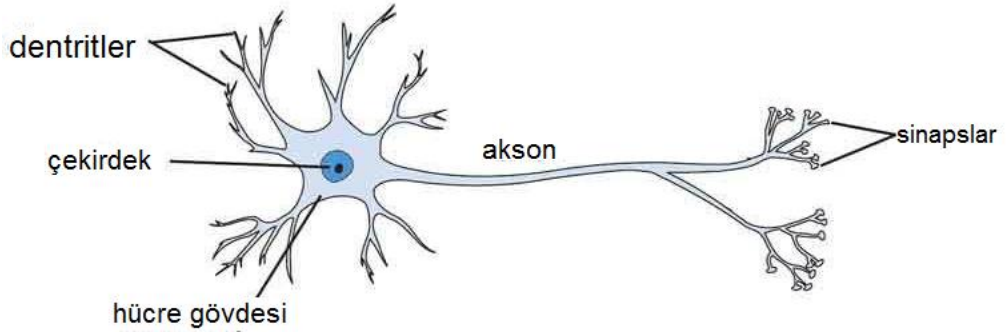
yöntemi kullanarak makine sađlığı izleme alıřması gerekleřtirmiřlerdir. Bu alıřmada öncelikle ham veriden özellikleri ıkarmak için ESA kullanılması daha sonra tahmin etme işleminin için ift yönlü UKDH kullanılması gerekleřtirilmiřtir. Wu vd. (2018), jet motorunda meydana gelen 4 eřit hatanın ne zaman gerekleřebileceğinin tahmin edilebilmesi için UKDH yapısının bir türevi vanilya UKDH yapısı kullanılmıřlardır. Bu alıřmada PHM topluluđu tarafından sunulan, hem sađlıklı hem de hatalı durumları içeren veriler kullanılmıřtır. Cornia vd. (2018), insan bakışının tek bir noktaya kilitlenmesi durumunu tahmin edebilmek için evriřimli UKDH yapısı kullanılmıřlardır. Xiao vd. (2019), android telefonlar için kötü niyetli yazılımlar ile güvenli yazılımları birbirinden ayırt etmek için UKDH yapısının dođal dil işleme özelliğinden faydalanılmıřlardır. Bu kapsamda %96,6 oranında dođruluk oranı elde etmiřlerdir.

2. YAPAY SINİR AĞLARI

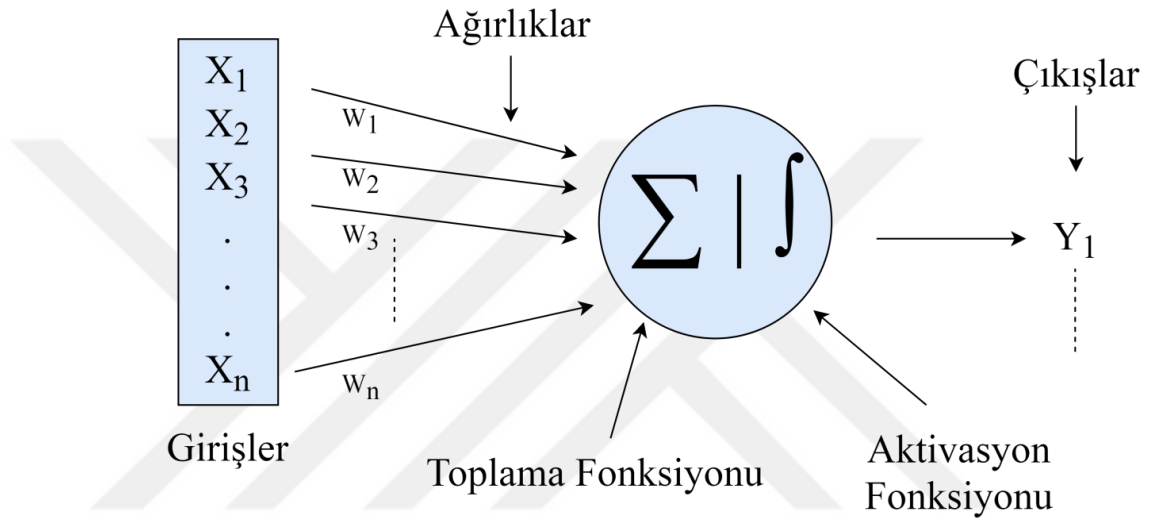
Teknolojideki gelişmelerle birlikte zaman içerisinde transistör ve daha sonra bilgisayar ortaya çıkmıştır. Bilgisayar kavramının ortaya çıkmasından hemen sonra makinelerin düşünebilmesi fikri ortaya atılmıştır. Günümüzde oldukça popüler olan makinelerin düşünmesi, makine öğrenmesi ve yapay zeka gibi fikirler aslında oldukça eskiye dayanmaktadır. McCulloch ve Pitts (1943) bu alanda yapılan ilk çalışmanın sahipleri olarak gösterilmektedirler. İlk defa matematiksel olarak basit bir yapay sinir ağı yapısı oluşturmuşlardır. Daha sonra Clark ve Farley (1954) kendileri oluşturdukları YSA yapısı ile makinelerin etkiye karşı tepki verebileceklerini göstermişlerdir. Werbos (1974), geri yayılım algoritmasını keşfetmiştir. Geri yayılım algoritması, yapay sinir ağlarının gelişimindeki en önemli kilometre taşlarından biridir. Bununla ilgili geri beslemeli yapay sinir ağı konusunda gerekli açıklamalar yapılmaktadır. Bu gelişmelerden sonra tekrar eden sinir ağları, evrişimli sinir ağları ve uzun-kısa dönem hafıza gibi yapılar geliştirilmiştir. Bu yapılar yapay sinir ağlarının temellerini oluştururlar.

Yapay sinir ağı, temelde insan beynindeki bilginin nörondan nörona hareket etmesi prensibine dayanmaktadır. Tıpkı insan beyninin bilgiyi başka bir bilgi kaynağından veya kendi tecrübeleri aracılığıyla öğrenmesi gibi makineler de bir bilgi kaynağından veya kendi işlemleri sonucunda bilgileri öğrenebilirler. Makine öğrenmesi alanında yapılan ilk çalışmalarda görülmektedir ki, makineler bilgiyi sadece dışarıdaki bir bilgi kaynağından almaya bağımlı idi. Son yıllarda yapılan çalışmalar şunu göstermektedir; makineler sadece bilgi kaynağından değil aynı zamanda kendi hatalarından ders çıkarma yöntemi ile de bilgileri öğrenebilmektedir. Bu işlemi uygulayabilen sinir ağlarına geri beslemeli sinir ağları denir. İlerleyen sayfalarda detaylı olarak açıklanmaktadır.

Şekil 2.1’de insan beynindeki iki adet biyolojik sinir hücresi ve aralarındaki bağlantılar gösterilmektedir. Biyolojik sinir hücresine benzer şekilde yapay sinir ağlarında da yapılar vardır. Biyolojik sinir hücresindeki nöronlar yapay sinir ağlarındaki işlemci elemanlara karşılık gelmektedir. Aynı şekilde dentritler toplama fonksiyonuna, hücre gövdesi aktivasyon fonksiyonuna, aksonlar çıkışlara ve sinapslar ağırlıklara karşılık gelmektedir.



Şekil 2.1. Biyolojik sinir hücresi yapısı.



Şekil 2.2. Yapay sinir hücresi yapısı.

Aktivasyon fonksiyonları, buldukları hücreye gelen verileri işleyerek hücrenin çıktısını belirleyen fonksiyonlardır. En yaygın kullanılan aktivasyon fonksiyonları; sigmoid, softmax, relu ve tanh şeklindedir.

$$\sigma = \frac{1}{1+e^{-x}} \quad (2.1)$$

Sigmoid fonksiyonu (2.1) eşitliği ile elde edilir. Bu fonksiyonda çıktı değerleri 0 ile 1 arasında değişir.

$$\tanh = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.2)$$

Hiperbolik tanjant fonksiyonu (2.2) eşitliği ile elde edilir. Bu fonksiyonda çıkış verileri -1 ile +1 arasında değişir.

$$\text{ReLU} = \begin{cases} 0 & x < 0 \\ x & x \geq 0 \end{cases} \quad (2.3)$$

ReLU fonksiyonu (2.3) eşitliği ile elde edilir. Bu fonksiyonda çıktı değerleri 0 ile sonsuz arasında değişir.

$$\text{softmax} = \frac{e^{x_j}}{\sum_{k=1}^K e^{x_k}} \quad (2.4)$$

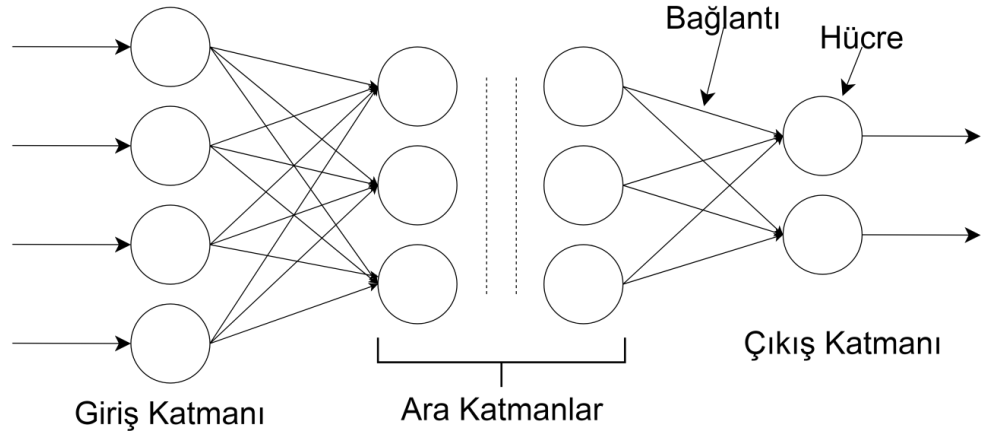
Softmax fonksiyonu (2.4) eşitliği ile elde edilir. Bu fonksiyonda çıktı değerleri 0 ile 1 arasında değişir. Çalışma sistemi olarak sigmoid fonksiyonuna benzer ancak her bir sınıf için ayrı işlem yapması sebebiyle çıkış katmanında kullanılır (Çayiroğlu, 2015).

Yapay sinir ağları tek katmanlı ve çok katmanlı olarak ikiye ayrılır. Tek katmanlı yapay sinir ağları giriş bölümü ve çıkış bölümü olmak üzere basit iki yapıdan oluşur. Giriş bölümü giriş verilerini alır ve ağırlık veya ağırlıklar ile işleme sokarak çıkış bölümüne iletir. Şekil 2.2’de verilen yapay sinir hücresi örneği aynı zamanda tek katmanlı yapay sinir ağına bir örnektir. Çok katmanlı yapay sinir ağları giriş bölümü, çıkış bölümü ve ara katmanlardan oluşur. Ara katmanlara gizli katmanlar da denilmektedir.

Çok katmanlı yapay sinir ağları da kendi içlerinde ileri beslemeli yapay sinir ağı ve geri beslemeli yapay sinir ağı olmak üzere ikiye ayrılır.

2.1 İleri Beslemeli Yapay Sinir Ağı

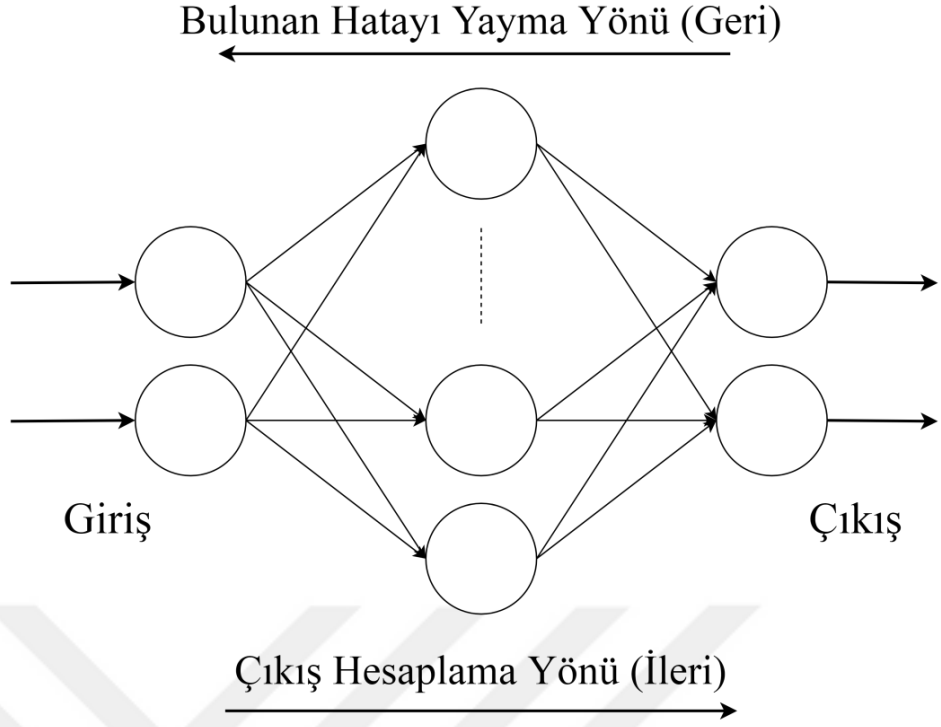
Şekil 2.3’te örnek bir çok katmanlı ileri beslemeli yapay sinir ağı gösterilmektedir. İleri beslemeli yapay sinir ağında giriş verisi giriş bölümü tarafından alınarak bir sonraki bölüme iletilir. Her katmanın çıkışı kendinden sonraki katmanın girişi olacak şekilde veriler iletilir. Çıkış bölümünden çıkış alınır.



Şekil 2.3. İleri beslemeli yapay sinir ağı.

2.2 Geri Beslemeli Yapay Sinir Ağı

Her yapay sinir ağında girişe karşılık bir istenen çıkış değeri vardır. İstenen çıkış değeri ile giriş değeri arasındaki farka hata fonksiyonu denir. Geri beslemeli yapay sinir ağında işlemler ileri beslemeli yapay sinir ağına benzer şekilde ilerledikten sonra elde edilen çıkış tekrar giriş bölümüne veya ara katmanlardan herhangi birine verilir. Buna ek olarak herhangi bir katmandan geriye dönüş yapmak da mümkündür. Bu işlem istenen sonuca ulaşana kadar tekrar edilebilir. Bu tekrar etme işlemine genel olarak döngü denilir. Geri beslemeli yapay sinir ağlarının temel özelliği geri yayılım algoritmasıdır. Geri yayılım algoritmasının görevi ise her döngüde ağırlıkları değiştirerek hata fonksiyonunu minimuma indirmektir. İdeal olarak hata sıfır olursa mükemmel bir tasarım yapılmış olur. Şekil 2.4'te geri beslemeli yapay sinir ağı örneği verilmektedir.



Şekil 2.4. Geri beslemeli yapay sinir ağı örneği.

Günümüzde yapay sinir ağları yapılarından ileri beslemeli yapay sinir ağı yapısı neredeyse hiç kullanılmamaktadır. Bunun sebebi ise günümüzde karmaşıklaşan sistemlerin ihtiyaçlarına yeterince cevap verememesidir. Bu yüzden bu çalışmada da geri beslemeli yapay sinir ağı yapısı tercih edilmektedir. Bu çalışmada geri beslemeli yapay sinir ağı yapılarından TSA ve UKDH yapıları kullanılmaktadır.


2.3 Derin Öğrenme

Derin öğrenme, YSA yapısının daha karmaşık şekli olarak düşünülebilir. Derin öğrenmenin YSA'dan farkı, karmaşık yapısı sayesinde yüksek miktarda veriyi işleyebilmesidir. Böyle karmaşık işlemleri gerçekleştirebilmek için çeşitli katmanlara ihtiyaç duyar. Bu çalışmada kullanılan katmanlar ilerleyen alt bölümlerde açıklanmaktadır.

2.3.1 Toplama (Pooling) Katmanı

Toplama katmanı, en basit anlamıyla bir örnek azaltma katmanıdır. Bu katmanda kullanılan çeşitli fonksiyonlar bulunmaktadır ancak en yaygını maksimum

toplama fonksiyonudur. Bu fonksiyonda veri parçalarına ayrılır ve bu parçalar birbirine geçişli olmayacak şekilde ayarlanır. Daha sonra her parçanın en büyük değeri alınır. Şekil 3.2’de örnek bir maksimum toplama işlemi gösterilmektedir.



Şekil 2.5. Maksimum toplama işlemi örneği.

Şekil 2.5’de bir boyutlu 4x4 boyutunda bir matrise uygulanan maksimum toplama işlemi örneği gösterilmektedir. Bu işlemde filtre boyutu 2x2 olarak seçilmiştir. Bu katmanda filtreler, verinin hangi boyutta bölümlere ayrılacağını belirler. Kaydırma parametresi ise 2’dir. Kaydırma parametresi, veri bölümlerinin tek seferde kaç birim ilerleyeceğini belirler. Böylece matris toplamda 4 parçaya ayrılır. Her parçanın en büyük değeri alınarak boyut azaltma işlemi gerçekleştirilir. Sonuçta bu işlem için 4x4 boyutunda bir matristen 2x2 boyutunda bir matris elde edilir. Bu işlem, görüntü işleme alanında en çok kullanılan yapılardandır. Bunun dışında diğer bir yapı da her parçanın ortalama değerini alma işlemidir. Giriş verisinin boyutu, filtrelerin boyutu ve kaydırma parametresi veri kümesine göre değişiklik gösterir.

2.3.2 Rectified Linear Unit (ReLU) Katmanı

ReLU katmanı, aktivasyon haritasındaki negatif değerleri sıfır ile değiştirmek için kullanılan bir fonksiyondur. ReLU fonksiyonundan başka sigmoid ve hiperbolik tanjant fonksiyonları da vardır. Sağladığı yüksek doğruluk ve işlemleri daha kısa sürede yapması gibi özelliklerinden dolayı diğerlerinden daha yaygın kullanıma sahiptir. ReLU fonksiyonu ile ilgili YSA bölümünde açıklama yapılmaktadır.

2.3.3 Tamamen Bağlı Katman

Tamamen bağlı katmanındaki her bir nöron kendisinden önceki ve kendisinden sonraki katmanlardaki tüm nöronlara bağlıdır. Bu katman, veriler

arasındaki bağlantı sayısını artırdığı için doğruluk oranını pozitif anlamda etkiler. Çoğu YSA mimarisinde kullanılmaktadır.


2.3.4 Kayıp Katmanı

Kayıp katmanı çok katmanlı bir YSA mimarisinin son katmanı olarak kullanılır. Bu katman, tahmin edilen değer ile gerçek değer arasındaki farkı hesaplar. Bu işlem için en çok kullanılan fonksiyonlar softmax fonksiyonu ve sigmoid fonksiyonudur. Sigmoid fonksiyonu ve softmax fonksiyonu ile ilgili önceki bölümde açıklama yapılmaktadır.




3. TEKRAR EDEN SINİR AĞLARI

Tekrar eden sinir ağı geri beslemeli yapay sinir ağlarının bir türüdür. Rumelhart (1986), tekrar eden sinir ağı ile ilgili yapılan ilk çalışmanın sahibi olarak gösterilir.



Şekil 3.1. Tekrar eden sinir ağlarının çalışma prensibi.

Tekrar eden sinir ağlarının çalışma prensibi sırasıyla şu şekildedir. Bu yapıda birbirini takip eden giriş verileri kullanılır. Şekil 3.1’de gösterildiği gibi x ile gösterilen değerler girişleri oluşturmaktadır. Her hücrede girişe karşılık bir çıkış değeri üretilerek bir sonraki hücre için giriş olarak kullanılır. Bu çıkış değerinden haric bir tane daha çıkış değeri üretilir ve bu harici çıkış değeri ise h ile gösterilmektedir. Her hücre için üretilen bu çıkış ve harici çıkış değeri birlikte bir sonraki hücrenin çıkışını tahmin etmek için işleme sokulur. Bu işlem hata fonksiyonu minimum değerine ulaşana kadar tekrar edilebilir. Bu sayede tahmin etme oranı kayda değer miktarda artırılmış olur. Bu şekilde işleyen bir sistem için kendi içinde bir hafızaya sahip olduğu söylenebilir. İnsanların düşünce sistemi de tıpkı bu sistem gibi çalışarak yeni karşılaştığı bir olayı daha önceden hafızasına yerleşmiş benzer bir olay ile karşılaştırır. Böylece yabancı olduğu durumu alışık olduğu bir duruma çevirerek sorunları daha kolay çözebilir.



Şekil 3.2. Tekrar eden sinir ağlarının örnek yapısı.


Şekil 3.2’de örnek bir tekrar eden sinir ağı yapısı gösterilmektedir. Bu sinir ağı yapısı birbirini takip eden ve çok fazla değişmeyen verileri işlemek için daha uygundur. Örneğin bu çalışmadaki gibi bir sistemin titreşim verileri anormal bir durum olmadığı sürece çok az değişikliğe uğrar. Bu gibi verilerde tekrar eden sinir ağlarını kullanmak mantıklıdır.

Tekrar eden sinir ağlarının birçok alanda avantajı olmasına rağmen önemli bir dezavantajı vardır. Tekrar eden sinir ağlarının en büyük dezavantajı, verinin en çok kendisinden hemen önceki veriye bağımlı olmasından kaynaklanmaktadır. Veriler kendisinden hemen önceki veriye en çok bağımlıyken veriler arasındaki fark açıldıkça bu bağımlılık azalır ve tahmin edilmesi zorlaşan bir durum oluşur. Şekil 3.1 üzerinden bu durum açıklanacak olursa; x_1 girişine karşılık üretilen h_1 çıkışı, x_2 girişi ile birlikte h_2 çıkışını tahmin etmek için kullanılır. Çıkışın h_4 olduğunu düşünürsek; eğer bir sonraki h_5 çıkışı, bir önceki çıkış olan h_4 ile değil ilk çıkış olan h_1 ile bağlantılı ise bu durumda bu yapı yetersiz kalacaktır. Örneğin “elektrik elektronik mühendisliği yüksek” kelimelerinden sonra “lisans” kelimesinin geleceğini tahmin etmek TSA için kolay bir görevdir. Ancak TSA için “Türkiye’de yaşayan insanlar” kelimelerinden sonra “Türkçe konuşur” kelimelerini tahmin etmek çok zor olacaktır. Yani verideki değişiklik az olduğu zaman TSA çok etkili iken, verideki değişiklik fazla olduğunda veya verinin ufak bir bölümünde aykırı bir durum olduğunda TSA yeterince etkili olmayacaktır. Bu sorunu ortadan kaldırmak için UKDH yöntemi geliştirilmiştir.

4. UZUN KISA DÖNEM HAFIZA


UKDH yapıları, TSA mimarileri içinde özel bir türdür. TSA'nın çözemediği bazı karmaşık sorunları çözebilmek için geliştirilmiştir. İlk kez Hochreiter ve Schmidhuber (1997), sabit hata döngüsü birimleri kullanarak giriş ile çıkış arasındaki hatayı yok etmeye çalışmışlardır. Bu ilk UKDH yapısı giriş hücreleri ve çıkış hücrelerinden oluşmaktadır. Gers vd. (1999), ilk kez UKDH yapısına hayali bir hücre eklemişlerdir. Gers vd. (2000), çıkış katmanına aktivasyon fonksiyonu eklemişlerdir. Cho vd. (2014), gated recurrent unit adını verdikleri basitleştirilmiş bir UKDH çeşidini ileri sürmüşlerdir. UKDH'nin başarılı olduğu alanlar arasında doğal dil işleme alanı ön plana çıkmaktadır. Google, Apple ve Microsoft gibi büyük firmaların çıkardığı ürünlerde doğal dil işleme, kelime tahmini, el yazısı tanıma ve çeviri yapma alanlarında sıklıkla kullanılmaktadır.

Tüm TSA yapıları, sinir ağının tekrar eden bir formuna sahiptir. Standart bir TSA yapısında bu tekrar eden form basit bir yapıdadır. Şekil 4.1'de tek bir hiperbolik tanjant aktivasyon fonksiyonuna sahip TSA yapısı gösterilmektedir. Bu aktivasyon fonksiyonu bütün ağ boyunca tekrar etmektedir.



Şekil 4.1. Basit TSA yapısı.

UKDH yapılarında ise tekrar eden basit form daha karmaşık hale getirilmiştir. Şekil 4.2'de 4 adet birbirini etkileyen aktivasyon fonksiyonu içeren UKDH yapısı gösterilmektedir. Bu 4 adet aktivasyon fonksiyonu bütün ağ boyunca tekrar etmektedir.



Şekil 4.2. Tekrar eden 4 adet aktivasyon fonksiyonlu UKDH yapısı.

Yukarıdaki şekilde görülebileceği gibi UKDH yapılarında hücreleri birbirine bağlayan iki adet hat bulunmaktadır. Üstteki hat aracılığıyla bilgiyi doğrudan bir sonraki hücreye iletmek mümkündür. Altteki hat aracılığıyla, çeşitli aktivasyon fonksiyonları ve matematiksel işlemler kullanarak bilgiye ekleme veya çıkarma yapılabilmektedir. Şekil 4.2’de “ σ ” ile gösterilen fonksiyon sigmoid fonksiyonudur, “ \tanh ” ile gösterilen fonksiyon hiperbolik tanjant fonksiyonudur.

UKDH işlemi 3 aşamada gerçekleşir. Birinci aşamada sigmoid fonksiyonu hangi sayıların işe yaramadığını belirler. Sigmoid fonksiyonu için veri 0 değerine ne kadar yakınsa o kadar işe yaramaz, 1 değerine ne kadar yakınsa o kadar değerlidir. Yeni gelen veri bir önceki veri ile benzerse değer 1’e yakın olur.

Sonraki aşamada bir adet hiperbolik tanjant fonksiyonu ve bir adet sigmoid fonksiyonu hücreye yeni gelen verilerden hangilerinin depolanacağına karar verir. Eğer yeni bilgi işe yarayan bir bilgi ise, bu aşamada eski bilgi unutulurken yeni bilgi kaydedilir.

Son aşamada hücrenin çıkışı belirlenir. Bu aşamada öncelikle bir sigmoid fonksiyonu hücreden hangi bölümlerin çıkışa verileceğini belirler. Daha sonra hücrenin durumu hiperbolik tanjant fonksiyonuna verilerek sadece istenilen verilerin çıkışı sağlanır.

5. MATERİYAL

Bu çalışmada materyal olarak veri kümesi ve bu veri kümesini işleyebilmek için *deeplearning4j* derin öğrenme kütüphanesi kullanılmaktadır. Kullanılan materyallerin detaylı açıklaması ilerleyen alt bölümlerde yapılmaktadır.

5.1 Veri Kümesi

Bu çalışmada, Verma vd. (2015) tarafından CNC makinesinin matkap ucunda oluşan çeşitli hataları teşhis etmek için oluşturulan veri kümesi kullanılmaktadır. Yapılan çalışmada Şekil 5.1’de gösterilen EMCO Concept Mill 105 isimli 3 eksenli bilgisayarlı CNC tezgahı kullanılmaktadır.



Şekil 5.1. EMCO concept mill 105 (Yang ve Xu, 2008).


Metal levhayı delmek için HSS Twist isimli 9mm çaplı matkap ucu kullanılmaktadır. Titreşim verisini yakalayabilmek için PCB 63001 isimli tek eksenli akselerometre kullanılmaktadır. Örnekleme frekansı 32768 Hz’dir. Titreşim verisini bilgisayar ortamına aktarmak için NI 9234 sinyal işleme birimi ve NI 9172 bilgisayar bağlantısı içeren veri elde etme sistemi kullanılmaktadır.

Titreşim verisi ölçülürken, dakikada 4mm, 8mm ve 12mm ilerleme hızlarına ek olarak 160, 170, 180, 190 ve 200 rpm dönme hızları kullanılmaktadır. Böylece toplamda 15 farklı varyasyon elde edilmektedir. Her varyasyon için hem metal levhayı delerken hem de metal levhayı deldikten sonra 8'er saniyelik titreşim verisi kaydedilmektedir. Bu işlem 3 adet hatalı durum ve 1 adet normal durum için tekrar edilir. Her bir durum için 30 adet 8 saniye uzunluğunda kayıt elde edilmektedir. Toplamda 120 adet 8 saniyelik kayıt elde edilmektedir. Veri kümesindeki hatalı durumların açıklaması aşağıdaki gibidir.

Birinci hatalı durum matkap ucunun körleşmesidir. Bu aşamada matkap ucunun körleşmesi gerçekleşir gerçekleşmez kayıt başlatılır. Yüksek sıcaklık ve ucun deforme olması sonucu oluşan körelme Şekil 5.2(a)'da gösterilmektedir.


İkinci hatalı durum matkap ucunun yan tarafından aşınmasıdır. Metal levha ile matkap ucu arasındaki sürtünme kuvvetinin etkisiyle aşınma meydana gelir. Şekil 5.2(b)'de gösterilen bu aşınma, matkap ucunun dönme hızı arttıkça çoğalmaktadır.

Üçüncü hatalı durum matkap ucunun dış köşesinin aşınmasıdır. Matkap ucu ile deliğin iç tarafı arasında meydana gelen yüksek sürtünme kuvveti sebebiyle matkap ucunun dış köşesi aşınıp buradan parça kopması gerçekleşebilir. Şekil 5.2(c)'de gösterilen bu aşınma, matkap ucunun bir köşesinde veya her iki köşesinde meydana gelebilir.




Şekil 5.2. Hata çeşitleri (a) körleşme (b) yan tarafın aşınması (c) dış köşe aşınması (Kanai ve Kenda, 1978).

Şekil 5.3'te, hatalı durumlara ait gerçek durum resimleri verilmektedir. Şekil 5.3(a) matkap ucunun körleşmesi, 5.3(b) yan tarafın aşınması ve 5.3(c) dış köşenin aşınması şeklindedir.




Şekil 5.3. Hatalı durumların gerçek resimleri (a) körleşme (b) yan taraf aşınması (c) dış köşe aşınması (Kumar vd., 2014).


Bu hatalı durumlara ek olarak bir tane de normal durum verisi sunulmaktadır.




Şekil 5.4. Matkap ucunun körleşmesi hatasının titreşim sinyali.



Şekil 5.5. Matkap ucunun yan tarafının aşınması hatasının titreşim sinyali.



Şekil 5.6. Matkap ucunun dış köşesinin aşınması hatasının titreşim sinyali.



Şekil 5.7. Normal durumun titreşim sinyali.


Hatalı durumlara ait titreşim sinyalleri sırasıyla Şekil 5.4, Şekil 5.5 ve Şekil 5.6'da gösterilmektedir. Normal duruma ait titreşim sinyali ise Şekil 5.7'de gösterilmektedir. Gösterilen titreşim sinyalleri, matkap ucu metal levhayı delerken dakikada 12 mm ilerleme hızı ve 200 rpm dönme hızı olduğu durumda alınan sinyallerdir.

Sonuç olarak, güncel bir şekilde endüstride kullanılan makineler tercih edilmesi ve en çok karşılaşılan hata durumlarını içermesi sebebiyle bu veri kümesi tercih sebebi olmaktadır.

5.2 Deeplearning4j Kütüphanesi

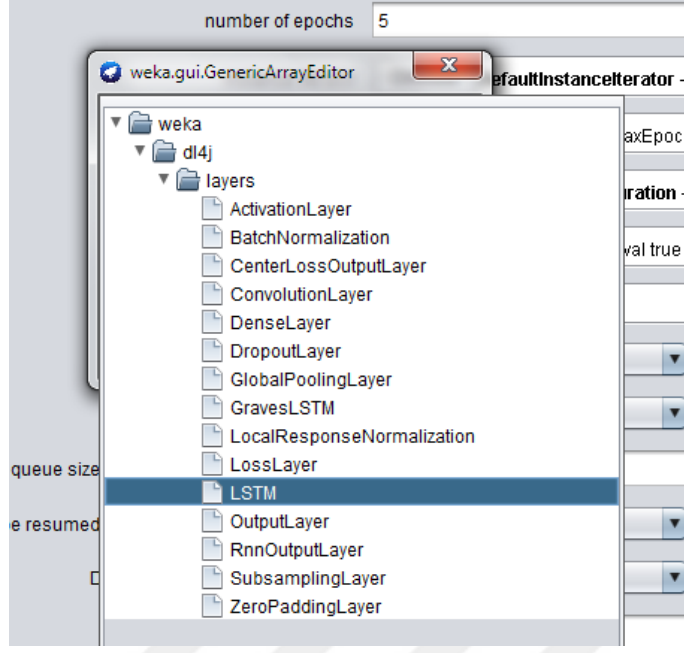
Deeplearning4j kütüphanesi, derin öğrenme algoritmaları için geniş çapta destek sunan JAVA programlama dilinde yazılmış bir kütüphanedir. Adam Gibson ve farklı kurumlardan bilim insanları tarafından ağustos 2017 tarihinde stabil sürümü yayınlanan kütüphane, açık kaynak türünde bir yazılım olması sayesinde gelişmeye devam etmektedir.

Deeplearning4j kütüphanesinin farklı kullanım seçenekleri bulunmaktadır. Bu çalışmada weka programı aracılığıyla işlemler gerçekleştirilmektedir. Kütüphane weka programına paket halinde yüklendikten sonra *classify* bölümünden işlemler gerçekleştirilir. Şekil 5.8'de kütüphanenin arayüzü gösterilmektedir.



Şekil 5.8. Weka programında deeplearning4j kütüphanesinin arayüzü (Lang vd., 2019).

Kütüphane arayüzü içerisinde bulunan *number of epochs* parametresi oluşturulan YSA yapısının kaç kez tekrar edeceğini belirler. Bu çalışmada tekrar sayısı 5 olarak belirlenmiştir. Diğer önemli parametre *layer specification* bölümüdür. Bu bölüm aracılığıyla katmanlar eklenip düzenlenebilir. Bu kütüphanede mevcut olan katmanlar Şekil 5.9’da gösterilmektedir.

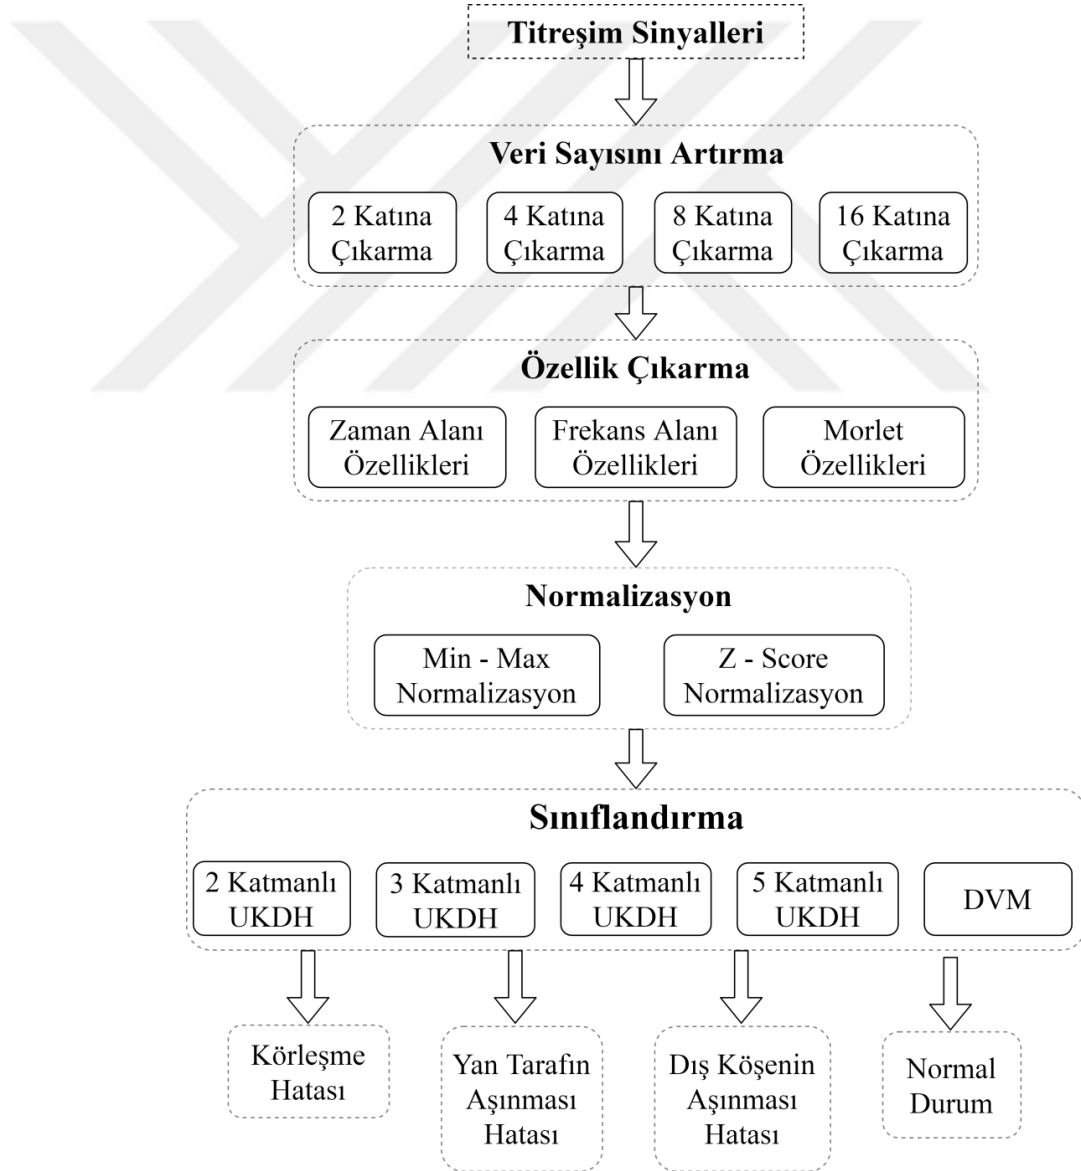


Şekil 5.9. Deeplearning4j kütüphanesinde sunulan katmanlar (Lang vd., 2019).

Bu çalışmada kullanılan katmanlar şu şekildedir; *LSTM* olarak gösterilen UKDH katmanı, *DenseLayer* olarak gösterilen tamamen bağlı katman, *GlobalPoolingLayer* olarak gösterilen toplama katmanı ve son olarak her yapıda bulunması zorunlu olan *OutputLayer* olarak gösterilen çıkış katmanı. Bu çalışmada kullanılan bu 4 katman ile 4 farklı çok katmanlı UKDH yapısı elde edilmektedir. Ayrıca UKDH katmanındaki aktivasyon fonksiyonların değişmesinin ve UKDH katmanının çıkış sayısının değişmesinin sonuca etkisi de deneysel sonuçlar bölümünde gösterilmektedir.

6. YÖNTEM

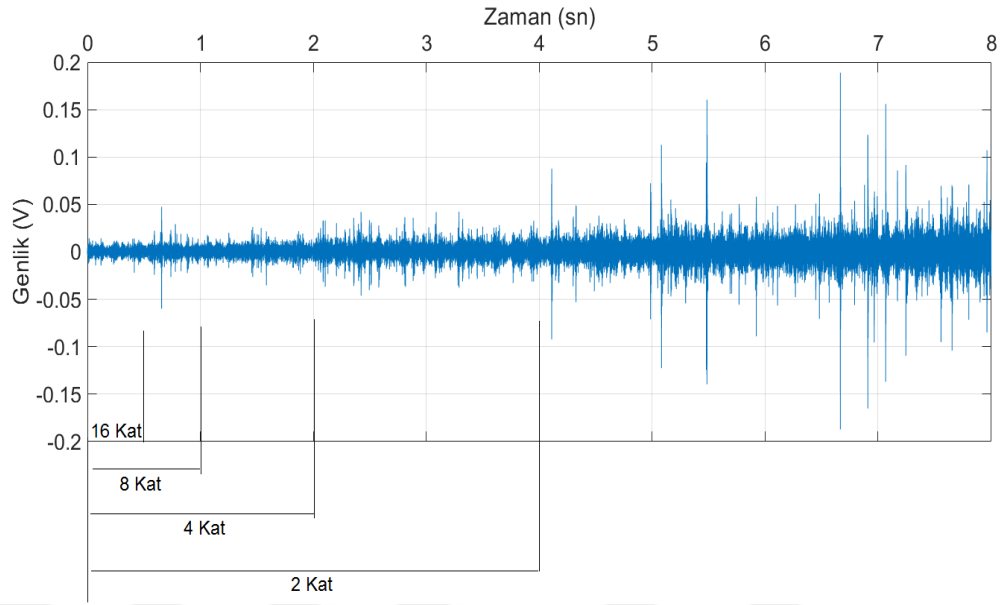
Şekil 6.1’de hata teşhisi için kullanılan yöntem aşamalar halinde gösterilmektedir. Bu çalışmada ilk olarak, doğruluk oranını doğrudan etkilediği için giriş verisi sayısı artırılmaktadır. Veri sayısı artırıldıktan sonra özellik çıkarma işlemi gerçekleştirilerek özellik matrisleri elde edilmektedir. Elde edilen özellik matrisleri için normalizasyon işlemi uygulanmaktadır. Normalizasyon işlemi gerçekleştirildikten sonra, hatalı ve normal durumların teşhis edilebilmesi için sınıflandırma algoritmaları uygulanmaktadır.



Şekil 6.1. Oluşturulan sistemin blok diyagramı.

6.1 Veri Sayısının Kademeli Olarak Artırılması

Veri sayısını artırmadaki amaç doğruluk oranını yükseltmektir. Yapılan arařtırmalarda görölmektedir ki veri sayısı arttıkça doğruluk oranı da belirli bir seviyeye kadar artmaktadır (Jing vd. 2017). Bu çalışmada kullanılan veri sayıları ařağıda açıklanmaktadır.



Şekil 6.2. Veri sayısını artırma işleminin gösterimi.

Şekil 6.2’de, veri sayısı artırılırken uygulanan yöntem, örnek bir titreşim sinyali grafiğı üzerinde gösterilmektedir. Ham veriden özellik çıkarma işlemi, her 8 saniye bir kez 21 özelliğın çıkarılması şeklinde belirlenmiştir. Bunun sonucunda her durum için 30 x 21 boyutunda özellik matrisi elde edilmektedir. Veri sayısını 2 katına çıkarabilmek için örnekleme zamanı 4 saniye olacak şekilde azaltılıp her durum için 60 x 21 boyutunda özellik matrisi elde edilmektedir. Aynı işlemler tekrar edilerek veri sayısı 4, 8 ve 16 katına çıkarılmaktadır. En son durumda, veri sayısı 16 katına çıkarılarak her bir durum için 480 x 21 boyutunda özellik matrisi elde edilmektedir.

Daha önce yapılan çalışmalar incelendiğinde görölmektedir ki, veri sayısının artmasının avantajı, elde edilen doğruluk oranının fazlaca artmasıdır. Veri sayısının artmasının dezavantajı ise işlem süresinin uzamasıdır.

6.2 Özellik Çıkarma

Özellik çıkarma işlemi için matlab programı ortamında yazılan kodlardan istifade edilmektedir. Bu kodlar, karışıklık olmaması sebebiyle ekler bölümünde verilmektedir.

6.2.1 Zaman Alanı Özellikleri

Zaman alanında 8 adet özellik elde edilmektedir. Bu özellikler; mutlak ortalama değeri, maksimum tepe noktası, karekök ortalama değeri, varyans, basıklık (kurtosis), tepe faktörü, şekil faktörü ve eğrilik (skewness) şeklindedir. Bu özellikler aşağıda açıklanmaktadır.

Mutlak ortalama değeri aşağıdaki gibi elde edilebilir,

$$\text{mAV} = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (6.1)$$

Burada N parametresi sinyaldeki toplam örnek sayısını ifade ederken, x_n parametresi n 'inci örneği temsil eder (Tkach vd., 2010).

Maksimum tepe noktası değeri, bir sinyalin genliğindeki en yüksek noktayı ifade eder.

Karekök ortalama değeri aşağıdaki eşitlik ile bulunabilir,

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N (x_n)^2} \quad (6.2)$$

Karekök ortalama değeri, bir dizi verideki değişimi hesaplamak için kullanılır (Cartwright, 2007). Etkin değer olarak da bilinmektedir.

Varyans değeri aşağıdaki eşitlik yardımı ile elde edilebilir,

$$\text{var} = \frac{1}{N-1} \sum_{n=1}^N x_n^2 \quad (6.3)$$

Varyans değeri sinyalin gücünü ölçmek için kullanılır (Tkach vd., 2010).

Kurtosis (basıklık) değeri aşağıdaki eşitlik ile bulunabilir,

$$\text{kurt} = \frac{\frac{1}{N} \sum_{n=1}^N x_n^4}{\sigma^4} \quad (6.4)$$

Burada σ parametresi standart sapma değerini ifade eder. Kurtosis, olasılık dağılımının tepe noktasını bulmak için kullanılır (Altın ve Er, 2016).

Tepe faktörü, maksimum tepe noktası değerinin karekök ortalama değerine bölünmesi ile elde edilir (Chatzimisios vd., 2010).

Şekil faktörü, etkin değerinin mutlak ortalama değere bölünmesi ile elde edilir.

Eğrilik (skewness) değeri aşağıdaki eşitlik ile elde edilir,

$$\text{skew} = \frac{\frac{1}{N} \sum_{n=1}^N x_n^3}{\sigma^3} \quad (6.5)$$

Eğrilik değeri, sinyaldeki asimetrikliğin bir ölçümüdür (Altın ve Er, 2016).

6.2.2 Frekans Alanı Özellikleri

Hızlı Fourier Dönüşümü (HFD) ve Ayrık Kosinüs Dönüşümü (AKD) aracılığıyla 8 adet özellik elde edilmektedir.

HFD, titreşim sinyali kullanılan uygulamalarda sıklıkla kullanılan bir yöntemdir. HFD, durağan olmayan sinyallerde, sinyalin frekans bileşenleri arasındaki enerji dağılımına dair ortalama bir resim sunar. HFD ile sinyalin hem faz hem de genlik değerleri elde edilir. Bir sinyali zaman alanından frekans alanına dönüştürmek için kullanılan en yaygın yöntemdir.

AKD, bir sinyaldeki enerji yoğunluğunu gösterir. Sinyal parçalara ayrılarak her parçanın enerji yoğunluğu hesaplanır.

6.2.3 Zaman-Frekans Alanı Özellikleri

Morlet Dalgacık Dönüşümü (MDD) aracılığıyla standart sapma, dalgacık entropisi, basıklık (kurtosis), eğrilik (skewness) ve varyans olmak üzere 5 adet özellik elde edilmektedir.

Standart sapma değeri aşağıdaki eşitlik ile bulunabilir (Altın ve Er, 2016).

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{n=1}^N x_n^2} \quad (6,6)$$

Dalgacık entropisi, dalgacık dönüşümü yardımıyla sinyaldeki düzenin veya düzensizliğin tahmin edilebilmesine olanak sağlar.

Basıklık, eğrilik ve varyans parametrelerinin açıklaması önceki bölümde yapıldığı için burada verilmemiştir.

6.3 Normalizasyon

Normalizasyon işlemi için iki adet yöntem belirlenmiştir. Literatür araştırmasında çoğunlukla min-max normalizasyon kullanıldığı görülmektedir. Karşılaştırma yapabilmek için bu yönteme ek olarak z-score normalizasyon yöntemi kullanılması uygun görülmüştür.

Min-max normalizasyon, aşağıdaki eşitlik ile uygulanabilir,

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (6,7)$$

Bu normalizasyon işlemi ile veriler 0 ile 1 arasında olacak şekilde yeniden düzenlenmiş olur. Veri içindeki en büyük değer ile en küçük değer arasındaki farkı en büyük değere çıkardığı için sıklıkla kullanılmaktadır.

Z-score normalizasyon, aşağıdaki eşitlik ile bulunabilir,

$$x_{norm} = \frac{x - \bar{x}}{\sigma} \quad (6,8)$$

Burada \bar{x} parametresi ortalama deęeri σ parametresi ise standart sapma deęerini ifade etmektedir.

Normalizasyon yöntemlerinden hangisinin verimli olduęu verinin yapısına göre deęişiklik göstermektedir.

6.4 Çok Katmanlı UKDH Yapılarını Oluşturma

Çok katmanlı sinir ağı yapıları oluşturulurken iki yöntem uygulanmaktadır. Birinci yöntemde YSA konusunda anlatılan katmanlar içinden en iyi sonucu veren yapı bulunmaya çalışılmaktadır. İkinci yöntemde, birinci yöntemde elde edilen sonuçların üzerine aktivasyon fonksiyonlarında ve çıkış sayılarında yapılan deęişiklikler gözlemlenmektedir.

Oluşturulan çok katmanlı yapılar sırasıyla şu şekildedir;

1. UKDH katmanı ve çıkış (**2 katman**),
2. UKDH katmanı, toplama katmanı, tamamen baęlı katman ve çıkış (**4 katman**),
3. UKDH katmanı, tamamen baęlı katman ve çıkış (**3 katman**),
4. UKDH katmanı, 3 tane tamamen baęlı katman ve çıkış (**5 katman**).

Katmanlar için kullanılan parametreler ařaęıdaki gibidir;

1. **UKDH katmanı** çıkış sayısı 10 ve 100 olarak iki farklı deęerde seçilmiştir,
2. **Toplama katmanı** kaydırma parametresi deęeri 2 olarak seçilmiştir,
3. **Tamamen baęlı katman** nöron sayısı 30 olarak seçilmiştir,
4. **Çıkış katmanı** çıkış sayısı 6 olarak seçilmiştir.

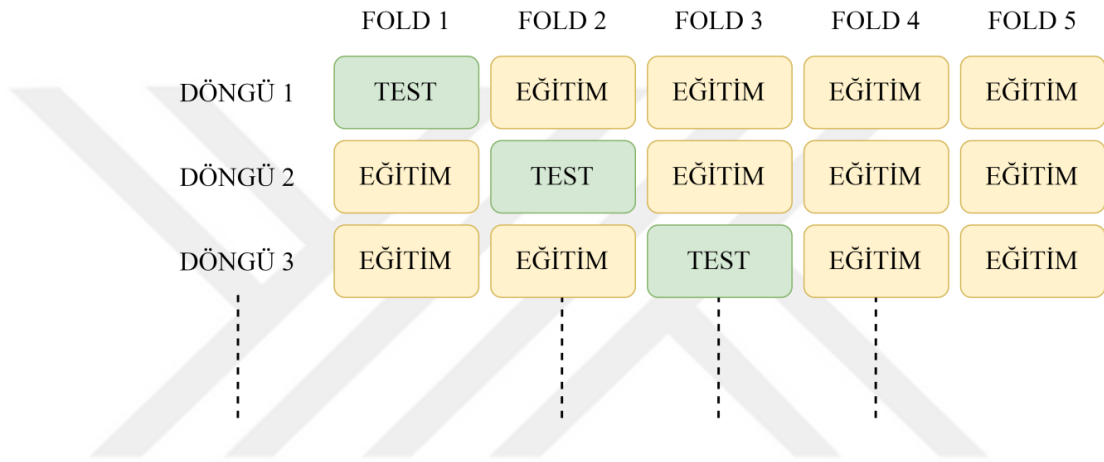
6.5 Sınıflandırma İşlemi İçin Kullanılan Veri Bölütleme Yöntemleri

Veriyi işleyebilmek için test ve eğitim verilerinin belirlenmesi gerekir. Bu çalışmada *k fold cross validation* ve *hold out* yöntemleri kullanılmaktadır.

6.5.1 K Fold Cross Validation Yöntemi

K fold cross validation yönteminde k deęişkeni kullanıcı tarafından belirlenir. Belirlenen k deęişkeni verinin kaç parçaya bölüneceğini belirler. Belirlenen k tane

bölümden her seferinde sadece bir parça test verisi olarak belirlenirken diğer parçalar eğitim verisi olarak belirlenir. Test için belirlenen parça sürekli değiştirilerek bütün parçaların test verisi olarak kullanılması sağlanır. Bu çalışmada k değeri 5 ve 10 olarak belirlenmiştir. K değeri yüksek seçildiğinde bilgisayarın bu veriyi bölümlere ayırıp işlemesi için gereken süre önemli ölçüde artmaktadır. Sürenin ne kadar artacağını belirleyen faktör, işlemlerin yapıldığı sistemin veri işleyebilme kapasitesidir. Bu sorunu gidermek için CUDA desteğine sahip GPU donanımı aracılığıyla işlemler yapılabilmektedir. Bu sayede işlemler 10 kata kadar daha hızlı yapılabilmektedir.




Şekil 6.3. K fold cross validation gösterimi.

Şekil 6.3'te k fold cross validation yönteminin çalışma sistemi gösterilmektedir.

6.5.2 Hold-Out Yöntemi

Hold-out yönteminde veri belirli bir yüzde oranında test ve eğitim verisi olarak bölünür. Bölünecek oran kullanıcı tarafından belirlenir.



Şekil 6.4. Hold out gösterimi (a) birinci yöntem (b) ikinci yöntem.

Şekil 6.4'te bu çalışmada kullanılan hold out yönteminin çalışma sistemi gösterilmektedir. Bu çalışmada iki adet hold-out oranı kullanılmaktadır. Birinci bölünme oranı % 50 eğitim % 50 test ve ikinci bölünme oranı % 70 eğitim % 30 test şeklinde belirlenmektedir. Bu yöntem k fold cross validation yöntemine göre daha hızlı işlem yapmaktadır ancak veri sayısı çok fazla olmadığı sürece iyi sonuç vermemektedir.

7. DENEYSEL SONUÇLAR

Bu bölümde, deneysel olarak elde edilen sonuçlar gösterilmektedir.

Yapılan deneyler sonucunda, toplama katmanının çıkışa etkisi olmadığı gözlemlenmiştir. Bu sebeple, toplama katmanının bulunduğu 4 katmanlı YSA mimarisi bu bölümünde gösterilmemektedir. Bu bölümde 2 katmanlı, 3 katmanlı ve 5 katmanlı YSA yapısına ek olarak DVM ile elde edilen sonuçlar gösterilmektedir.

Elde edilen sonuçlar sayıca çok fazla olduğu için bu bölüm kendi içinde alt bölümlere ayrılmaktadır. Zaman Alanı Özellikleri, Frekans Alanı Özellikleri, Zaman-Frekans Alanı Özellikleri ve bunların birleşiminden oluşan Tüm Özellikler olmak üzere toplamda 4 alt bölüm halinde sonuçlar gösterilmektedir. Her bölümde;

1. UKDH çıkışı 10 olduğu ve aktivasyon fonksiyonunun ReLU olduğu yöntem,
2. UKDH çıkışı 10 olduğu ve aktivasyon fonksiyonunun TANH olduğu yöntem,
3. UKDH çıkışı 100 olduğu ve aktivasyon fonksiyonunun TANH olduğu yöntem,
4. DVM ile elde edilen doğruluk oranları olmak üzere toplamda 4 yöntem halinde tablolar verilmektedir.

Her yöntem için 5 fold cross validation, 10 fold cross validation, 50-50 hold out ve 70-30 hold out olmak üzere 4 adet veri bölütleme işlemi ile sınıflandırmalar gerçekleştirilmektedir.

Bu çalışmada, doğruluk oranlarına ek olarak hata matrisleri ve ortalama değerler de gösterilmektedir. Her durum için en iyi doğruluk oranını veren sonucun hata matrisi ve ortalama değerleri tablolar halinde gösterilmektedir.

Bu çalışmada, gerçekleştirilen tüm işlemler için bilgisayarın işlemi gerçekleştirme süresi ölçülmektedir. Her durum için ortalama işlem süreleri tablolar halinde gösterilmektedir.

7.1 Zaman Alanı Özellikleri Sonuçları

Bu bölümde, sadece zaman alanında çıkarılan özellikler kullanılarak elde edilen sonuçlar gösterilmektedir.

Çizelge 7.1. Zaman alanında birinci yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	40,83	23,33	35,83	50,83	18,33	25,00	53,33	21,67	38,33
2 Kat	56,67	25,00	35,00	59,58	27,92	32,92	65,42	30,42	32,08
4 Kat	60,42	29,17	34,58	66,67	36,04	37,08	71,67	50,62	37,92
8 Kat	68,44	35,42	34,69	73,85	42,60	39,68	87,60	61,14	39,27
16 Kat	78,49	39,53	35,78	88,90	71,72	41,35	91,15	83,96	40,16
10 Fold Cross Validation									
Orijinal	43,33	25,00	38,33	50,00	23,33	27,50	52,50	19,17	40,00
2 Kat	55,83	24,58	35,00	57,08	29,17	30,00	66,25	29,58	30,42
4 Kat	61,46	27,92	34,79	68,12	35,00	35,62	73,54	49,79	36,46
8 Kat	68,96	35,73	36,46	74,17	43,75	40,42	88,54	60,42	38,54
16 Kat	79,89	40,88	35,94	89,11	74,68	41,82	90,00	85,21	41,77
50 – 50 Hold Out									
Orijinal	30,00	23,33	31,67	40,00	26,67	25,00	36,67	23,33	23,33
2 Kat	40,00	22,50	29,17	47,50	21,67	23,33	45,00	16,67	30,83
4 Kat	51,67	26,25	35,00	56,25	29,58	35,00	54,58	34,58	34,58
8 Kat	63,12	28,75	34,17	68,33	36,46	34,37	82,29	38,96	34,37
16 Kat	76,04	37,29	35,62	85,00	64,48	37,18	88,33	79,06	36,56
70 – 30 Hold Out									
Orijinal	33,33	19,44	30,56	55,55	19,44	30,55	36,11	19,44	27,78
2 Kat	40,28	19,44	27,78	62,50	22,22	27,78	59,72	27,78	31,94
4 Kat	56,94	31,25	35,42	64,58	29,17	32,64	63,89	52,08	37,50
8 Kat	66,32	30,55	32,29	70,48	38,19	34,72	80,90	49,65	29,86
16 Kat	77,26	38,71	36,28	84,37	70,14	42,01	90,10	80,90	40,62

Çizelge 7.1’de zaman alanı özellikleri ile elde edilen, UKDH çıkışının 10 ve aktivasyon fonksiyonun ReLU olduğu duruma ait doğruluk oranları yüzdesel olarak gösterilmektedir.

Çizelge 7.2. Zaman alanında ikinci yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	53,33	20,00	33,33	60,00	15,83	32,50	70,00	18,33	36,67
2 Kat	58,33	22,92	35,42	62,50	26,67	31,25	78,33	36,25	32,92
4 Kat	61,87	28,54	34,17	67,08	35,20	36,87	81,46	53,12	37,92
8 Kat	67,60	34,69	34,79	76,56	51,35	37,39	88,54	69,58	44,06
16 Kat	81,04	40,26	36,56	89,27	77,60	41,20	94,27	88,59	44,63
10 Fold Cross Validation									
Orijinal	54,17	17,50	34,17	64,17	16,67	33,33	70,00	20,83	34,17
2 Kat	59,58	24,17	32,08	65,83	23,75	30,83	76,25	36,25	33,33
4 Kat	60,83	27,92	35,00	70,00	38,96	36,25	85,21	55,20	40,62
8 Kat	68,85	35,42	34,79	77,71	51,56	37,92	88,96	74,89	43,44
16 Kat	81,61	43,02	36,30	90,94	79,06	41,04	93,80	88,12	46,20
50 – 50 Hold Out									
Orijinal	36,67	16,67	30,00	46,67	18,33	31,67	58,33	21,67	33,33
2 Kat	51,67	22,50	28,33	60,83	20,83	23,33	69,17	23,33	30,83
4 Kat	53,33	22,92	33,33	56,25	24,17	33,75	59,17	37,92	35,00
8 Kat	63,75	33,54	33,75	70,62	39,17	35,42	85,62	55,00	41,46
16 Kat	77,50	37,60	36,25	86,56	69,17	38,12	85,83	87,39	45,52
70 – 30 Hold Out									
Orijinal	44,44	22,22	36,11	50,00	22,22	25,00	69,44	27,78	33,33
2 Kat	68,05	11,11	31,94	66,67	12,50	30,55	84,72	26,38	31,94
4 Kat	57,64	28,47	32,64	65,28	33,33	32,64	78,47	52,08	33,33
8 Kat	67,01	34,37	34,03	74,30	46,18	36,46	85,07	56,59	38,89
16 Kat	79,68	39,93	34,89	84,89	73,96	39,06	92,18	83,68	45,66

Çizelge 7.2’de zaman alanı özellikleri ile elde edilen, UKDH çıkışının 10 ve aktivasyon fonksiyonunun TANH olduğu duruma ait doğruluk oranları yüzdesel olarak gösterilmektedir.

Çizelge 7.3. Zaman alanında üçüncü yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	55,00	12,50	35,83	63,33	13,33	37,50	72,50	16,67	35,00
2 Kat	62,08	27,08	32,50	72,08	31,25	34,58	77,92	34,17	33,75
4 Kat	67,71	34,37	36,87	76,25	40,62	38,75	84,79	56,25	38,54
8 Kat	83,12	42,81	38,65	88,85	59,37	40,83	87,71	72,50	42,29
16 Kat	89,17	65,05	40,68	92,66	87,24	41,50	92,66	89,27	43,02
10 Fold Cross Validation									
Orijinal	59,17	12,50	40,83	66,67	14,17	37,50	71,67	20,83	34,17
2 Kat	62,50	21,67	35,42	75,83	25,00	34,17	78,75	32,92	35,83
4 Kat	70,00	35,62	38,75	80,42	44,58	38,96	85,62	59,17	41,87
8 Kat	86,04	43,44	40,21	88,75	62,08	42,19	89,58	80,94	46,77
16 Kat	90,88	71,15	41,56	92,24	88,65	43,80	92,60	89,69	48,85
50 – 50 Hold Out									
Orijinal	53,33	25,00	31,67	56,67	18,33	30,00	60,00	23,33	30,00
2 Kat	60,83	20,83	28,33	63,33	20,83	28,33	64,17	23,33	29,17
4 Kat	57,08	23,33	32,92	59,17	25,83	34,58	62,92	35,83	33,75
8 Kat	74,79	34,17	37,71	83,96	44,58	38,54	88,96	52,29	37,71
16 Kat	86,25	54,79	36,67	89,06	80,31	38,54	89,48	88,33	47,50
70 – 30 Hold Out									
Orijinal	52,78	25,00	30,55	58,33	30,55	36,11	69,44	33,33	36,11
2 Kat	72,22	15,28	30,55	75,00	18,05	29,17	76,39	26,39	31,94
4 Kat	62,50	28,47	30,55	70,14	34,72	31,94	84,72	54,17	33,33
8 Kat	77,78	39,24	38,19	85,42	51,74	37,85	86,11	60,76	37,50
16 Kat	86,46	61,28	40,97	90,80	85,24	44,27	91,32	84,20	45,83

Çizelge 7.3'te zaman alanı özellikleri ile elde edilen, UKDH çıkışının 100 ve aktivasyon fonksiyonunun TANH olduğu duruma ait doğruluk oranları yüzdesel gösterilmektedir.

Çizelge 7.4. Zaman alanında DVM yöntemi kullanılarak elde edilen doğruluk oranları (%).

Giriş Sayısı	5 Fold Cross Validation			10 Fold Cross Validation		
	minmax	z-score	normal	minmax	z-score	normal
Orijinal	48,33	18,33	33,33	53,33	15,83	35,00
2 Kat	60,00	20,42	31,67	61,67	11,25	37,08
4 Kat	71,87	22,08	38,12	73,33	16,87	36,67
8 Kat	72,29	20,83	35,73	72,71	19,17	35,42
16 Kat	84,17	21,15	34,27	84,58	21,20	34,48
	50 – 50 hold Out			70 – 30 hold Out		
Orijinal	53,33	18,33	26,67	50,00	13,89	27,78
2 Kat	51,67	20,00	24,17	52,78	9,72	30,55
4 Kat	62,50	21,67	28,75	74,30	11,11	29,86
8 Kat	70,42	23,12	35,83	72,57	22,57	35,76
16 Kat	78,02	23,02	33,33	79,51	21,18	30,73

Çizelge 7.4’te, zaman alanında DVM aracılığıyla elde edilen doğruluk oranları yüzdesel olarak gösterilmektedir.

Çizelge 7.5. Zaman alanında elde edilen en iyi sonuçların hata matrisleri.

	Birinci Yöntem (%91,15)				İkinci Yöntem (%94,27)				Üçüncü Yöntem (%92,66)				DVM (%84,58)			
	a	b	c	d	a	b	c	d	a	b	c	d	a	b	c	d
A=0	445	23	3	9	454	16	5	5	436	29	8	7	435	25	11	9
B=1	7	439	34	0	11	439	29	1	16	438	26	0	12	370	97	1
C=2	32	50	396	2	10	27	443	0	17	31	432	0	56	69	350	5
D=3	10	0	0	470	6	0	0	474	7	0	0	473	6	2	3	469

Çizelge 7.6. Zaman alanında elde edilen en iyi sonuçların ortalama değerleri.

	TPR	FPR	Precision	Recall	F Measure	MCC	ROC Area	PRC Area
Birinci Yöntem	0,911	0,030	0,912	0,911	0,911	0,882	0,984	0,953
İkinci Yöntem	0,943	0,019	0,943	0,943	0,943	0,924	0,993	0,981
Üçüncü Yöntem	0,927	0,024	0,927	0,927	0,927	0,902	0,991	0,973
DVM	0,846	0,051	0,844	0,846	0,845	0,794	0,928	0,786

Zaman alanında elde edilen en iyi sonuçlara ait hata matrisleri Çizelge 7.5'te, ortalama değerler ise Çizelge 7.6'da gösterilmektedir.

7.2 Frekans Alanı Özellikleri Sonuçları

Bu bölümde, sadece frekans alanında çıkarılan özellikler kullanılarak elde edilen sonuçlar gösterilmektedir.

Çizelge 7.7. Frekans alanında birinci yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	34,17	20,83	63,33	39,17	21,67	64,17	40,83	27,50	66,67
2 Kat	44,58	23,75	73,75	51,67	27,92	78,75	62,50	32,50	75,83
4 Kat	62,29	30,21	77,71	66,67	35,42	79,58	72,08	42,29	78,75
8 Kat	71,67	40,10	78,75	71,77	48,44	81,04	77,70	56,35	80,00
16 Kat	76,35	50,83	81,51	79,01	58,33	83,33	86,61	65,73	84,74
10 Fold Cross Validation									
Orijinal	36,67	21,67	65,00	40,83	26,67	65,83	43,33	20,00	65,00
2 Kat	46,25	22,08	74,58	50,42	27,50	79,17	62,92	37,08	72,08
4 Kat	64,37	33,12	78,33	67,29	38,33	78,75	71,04	44,58	75,83
8 Kat	71,46	41,35	78,65	72,50	50,73	80,52	77,50	58,23	81,25
16 Kat	77,55	52,13	80,94	81,82	62,39	83,28	88,28	67,86	84,74
50 – 50 Hold Out									
Orijinal	31,67	18,33	45,00	21,67	20,00	35,00	30,00	25,00	60,00
2 Kat	41,67	20,83	70,00	46,67	21,67	71,67	56,67	19,17	74,17
4 Kat	58,75	27,08	76,25	58,75	27,08	78,33	60,83	33,75	78,75
8 Kat	63,54	31,67	75,42	64,37	35,42	78,54	71,87	44,17	76,46
16 Kat	70,10	44,27	78,96	76,87	53,96	82,29	84,69	64,06	83,75
70 – 30 Hold Out									
Orijinal	16,67	11,11	66,67	25,00	16,67	69,44	22,22	16,67	69,44
2 Kat	41,67	19,44	65,28	44,44	27,78	73,61	59,72	23,61	76,38
4 Kat	65,28	24,30	78,47	69,44	31,25	82,64	68,75	33,33	81,25
8 Kat	70,83	38,54	75,35	73,61	40,97	79,51	81,25	52,43	78,82
16 Kat	77,08	47,74	80,03	78,99	55,21	82,98	86,28	65,10	84,03

Çizelge 7.7’de frekans alanı özellikleri ile elde edilen, UKDH çıkışının 10 ve aktivasyon fonksiyonunun ReLU olduğu duruma ait doğruluk oranları yüzdesel olarak gösterilmektedir.

Çizelge 7.8. Frekans alanında ikinci yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	40,00	23,33	60,83	45,00	21,67	66,67	49,17	30,00	71,67
2 Kat	55,83	24,17	72,50	55,00	27,08	77,08	66,67	40,83	80,00
4 Kat	66,87	32,92	76,46	68,12	37,71	80,00	77,92	46,87	80,00
8 Kat	70,10	41,56	79,79	76,25	50,21	80,31	77,71	61,35	79,79
16 Kat	80,88	53,75	82,50	84,32	61,46	83,59	88,91	70,42	83,75
10 Fold Cross Validation									
Orijinal	43,33	24,17	60,83	50,83	25,00	65,83	48,33	30,00	71,67
2 Kat	55,00	24,58	72,08	57,50	25,83	78,33	67,50	38,75	80,42
4 Kat	68,12	33,75	77,08	70,42	38,12	79,58	76,25	47,29	78,96
8 Kat	70,52	41,77	78,85	77,60	49,68	80,10	79,79	61,04	81,77
16 Kat	81,72	55,00	82,45	85,26	63,96	83,18	90,10	77,03	84,27
50 – 50 Hold Out									
Orijinal	25,00	20,00	40,00	36,67	23,33	51,67	36,67	18,33	68,33
2 Kat	40,00	27,50	66,67	44,17	27,50	67,50	55,00	20,83	75,83
4 Kat	59,58	26,67	74,17	65,83	31,25	79,58	67,08	38,75	78,33
8 Kat	65,62	33,96	68,33	70,21	39,17	76,46	73,75	50,00	76,25
16 Kat	75,62	48,02	80,10	81,77	58,65	82,39	87,92	65,42	83,33
70 – 30 Hold Out									
Orijinal	16,67	8,33	52,78	33,33	13,89	52,78	33,33	13,89	77,78
2 Kat	52,78	30,55	63,89	51,39	25,00	68,05	77,78	31,94	76,39
4 Kat	70,83	33,33	76,39	71,53	34,03	84,03	75,69	43,05	82,64
8 Kat	70,14	38,54	77,08	75,69	46,53	80,90	81,25	57,29	81,25
16 Kat	78,99	52,26	82,12	83,16	56,77	83,68	87,50	69,96	83,33

Çizelge 7.8’de frekans alanı özellikleri ile elde edilen, UKDH çıkışının 10 ve aktivasyon fonksiyonunun TANH olduğu duruma ait doğruluk oranları yüzdesel olarak gösterilmektedir.

Çizelge 7.9. Frekans alanında üçüncü yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	48,33	13,33	69,17	48,00	17,50	72,50	59,17	23,33	71,67
2 Kat	67,08	29,17	80,42	67,08	32,92	80,42	68,33	37,08	77,92
4 Kat	72,71	42,08	81,04	75,00	45,83	81,87	78,75	50,00	79,17
8 Kat	77,71	52,50	81,15	79,58	60,21	81,35	78,96	68,33	80,83
16 Kat	87,03	66,87	84,32	89,32	72,66	85,31	91,04	81,35	84,27
10 Fold Cross Validation									
Orijinal	52,50	11,67	68,33	52,50	17,50	75,83	58,33	25,83	71,67
2 Kat	67,92	32,92	80,83	69,17	36,67	80,83	68,75	34,58	79,58
4 Kat	73,12	44,58	78,75	76,67	46,46	79,58	80,62	53,33	81,04
8 Kat	78,12	56,25	81,04	80,73	62,19	81,56	80,42	72,60	81,98
16 Kat	87,40	69,17	84,17	90,57	74,79	85,78	92,34	83,75	84,69
50 – 50 Hold Out									
Orijinal	40,00	13,33	73,33	38,33	21,67	76,67	40,00	30,00	76,67
2 Kat	53,33	19,17	70,00	60,00	24,17	74,17	70,83	23,33	76,67
4 Kat	70,00	34,17	78,33	70,00	38,75	79,58	70,00	40,42	77,08
8 Kat	73,54	46,67	76,46	74,17	50,21	77,50	72,71	59,17	74,79
16 Kat	84,17	60,73	82,40	86,67	68,33	84,06	89,79	77,92	83,96
70 – 30 Hold Out									
Orijinal	38,89	13,89	77,78	44,44	13,89	77,78	50,00	13,89	72,22
2 Kat	69,44	23,61	70,83	69,44	36,11	77,78	75,00	38,89	73,61
4 Kat	74,30	39,58	82,64	73,61	42,36	82,64	81,94	51,39	83,33
8 Kat	78,47	51,04	79,86	80,90	55,21	81,25	79,86	66,32	81,94
16 Kat	85,59	64,24	82,81	88,19	70,83	84,03	92,01	81,60	82,46

Çizelge 7.9’da frekans alanı özellikleri ile elde edilen, UKDH çıkışının 100 ve aktivasyon fonksiyonunun TANH olduğu duruma ait doğruluk oranları yüzdesel gösterilmektedir.

Çizelge 7.10. Frekans alanında DVM yöntemi kullanılarak elde edilen doğruluk oranları (%).

Giriş Sayısı	5 Fold Cross Validation			10 Fold Cross Validation		
	minmax	z-score	normal	minmax	z-score	normal
Orijinal	51,67	12,50	67,50	50,83	10,00	70,00
2 Kat	56,25	14,17	75,42	56,67	10,83	75,42
4 Kat	65,21	20,00	77,08	66,46	14,58	77,50
8 Kat	61,77	19,69	77,71	61,87	18,02	77,81
16 Kat	73,18	23,18	79,43	73,33	17,92	79,48
	50 – 50 hold Out			70 – 30 hold Out		
Orijinal	36,67	16,67	43,33	30,55	11,11	72,22
2 Kat	45,83	15,83	75,83	56,94	15,28	65,28
4 Kat	64,58	24,17	77,08	65,97	18,75	79,17
8 Kat	57,92	22,92	73,75	60,42	21,53	75,00
16 Kat	70,83	25,00	78,85	72,05	25,69	80,90

Çizelge 7.10’da, frekans alanında DVM aracılığıyla elde edilen doğruluk oranları gösterilmektedir.

Çizelge 7.11. Frekans alanında elde edilen en iyi sonuçların hata matrisleri.

	Birinci Yöntem (%88,28)				İkinci Yöntem (%90,10)				Üçüncü Yöntem (%92,34)				DVM (%80,90)			
	a	b	c	d	a	b	c	d	a	b	c	d	a	b	c	d
A=0	447	12	17	4	451	7	14	8	458	5	12	5	101	21	0	0
B=1	13	434	27	6	10	442	22	6	10	439	23	8	8	143	0	1
C=2	31	48	365	36	33	30	390	27	14	20	418	28	0	2	103	47
D=3	2	6	23	449	3	7	23	447	1	1	20	458	0	0	31	119

Çizelge 7.12. Frekans alanında elde edilen en iyi sonuçların ortalama değerleri.

	TPR	FPR	Precision	Recall	F Measure	MCC	ROC Area	PRC Area
Birinci Yöntem	0,883	0,039	0,882	0,883	0,881	0,843	0,978	0,947
İkinci Yöntem	0,901	0,033	0,900	0,901	0,900	0,868	0,985	0,964
Üçüncü Yöntem	0,923	0,026	0,923	0,923	0,923	0,898	0,990	0,976
DVM	0,809	0,067	0,812	0,809	0,808	0,745	0,929	0,753

Frekans alanında elde edilen en iyi sonuçlara ait hata matrisleri Çizelge 7.11’de, ortalama değerler ise Çizelge 7.12’de gösterilmektedir.

7.3 Zaman-Frekans Alanı Özellikleri Sonuçları

Bu bölümde, sadece zaman-frekans alanında çıkarılan özellikler kullanılarak elde edilen sonuçlar gösterilmektedir.

Çizelge 7.13. Zaman-frekans alanında birinci yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	35,83	28,33	31,67	41,67	18,33	30,00	42,50	31,67	30,00
2 Kat	53,33	26,25	35,42	51,67	29,58	36,67	64,58	40,00	39,17
4 Kat	70,00	34,37	36,67	77,08	41,87	38,33	86,25	58,75	38,33
8 Kat	82,08	34,37	37,18	84,68	47,71	41,56	87,71	64,79	39,37
16 Kat	84,89	34,48	39,58	91,14	46,67	42,24	91,87	66,25	41,25
10 Fold Cross Validation									
Orijinal	34,17	27,50	30,00	42,50	17,50	30,00	44,17	33,33	25,00
2 Kat	53,75	27,08	35,42	52,08	27,92	36,67	63,33	41,25	34,58
4 Kat	73,12	33,96	37,50	80,83	43,54	40,62	86,46	63,33	41,04
8 Kat	81,56	32,92	38,02	84,17	43,23	42,50	88,02	64,37	40,52
16 Kat	85,52	35,15	39,74	91,40	49,35	44,68	91,09	68,49	42,13
50 – 50 Hold Out									
Orijinal	30,00	23,33	21,67	30,00	18,33	23,33	36,67	23,33	25,00
2 Kat	43,33	20,83	27,50	49,17	20,83	24,17	59,17	26,67	26,67
4 Kat	65,83	28,75	35,83	67,08	31,25	40,83	83,33	42,50	37,08
8 Kat	71,87	35,00	33,96	80,00	42,08	35,00	84,37	59,17	34,58
16 Kat	82,29	33,33	39,17	86,25	39,68	41,67	87,92	56,46	40,21
70 – 30 Hold Out									
Orijinal	30,55	13,89	22,22	33,33	22,22	25,00	36,11	30,55	11,11
2 Kat	43,05	16,67	31,94	51,39	16,67	27,78	62,50	31,94	30,55
4 Kat	72,22	34,03	39,58	74,30	38,19	37,50	88,89	59,03	43,05
8 Kat	83,68	34,72	37,50	85,07	38,89	37,15	88,89	63,89	34,37
16 Kat	85,42	33,68	40,45	90,28	44,27	43,75	92,01	62,85	39,76

Çizelge 7.13'te zaman-frekans alanı özellikleri ile elde edilen, UKDH çıkışının 10 ve aktivasyon fonksiyonun ReLU olduğu duruma ait doğruluk oranları yüzdesel olarak gösterilmektedir.

Çizelge 7.14. Zaman-frekans alanında ikinci yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	45,83	30,83	33,33	45,00	17,50	32,50	55,00	35,00	32,50
2 Kat	57,50	24,58	32,92	60,00	26,67	35,42	69,58	45,42	37,08
4 Kat	72,50	28,54	36,46	81,25	37,50	40,00	86,04	59,37	41,04
8 Kat	82,39	34,17	37,50	85,94	45,62	40,42	90,73	59,89	43,65
16 Kat	85,31	41,04	40,88	91,67	53,85	40,21	93,18	68,91	41,15
10 Fold Cross Validation									
Orijinal	47,50	28,33	35,00	47,50	15,00	30,00	55,00	30,83	30,83
2 Kat	52,08	25,83	34,58	60,83	27,08	34,17	68,33	42,50	35,83
4 Kat	75,00	27,50	36,46	84,79	40,83	41,45	89,17	62,70	43,12
8 Kat	83,23	34,48	37,50	88,33	47,08	40,94	89,37	64,79	41,77
16 Kat	86,20	39,89	40,88	92,76	55,05	42,29	93,65	72,66	43,38
50 – 50 Hold Out									
Orijinal	28,33	20,00	21,67	41,67	25,00	31,67	45,00	30,00	26,67
2 Kat	50,00	28,33	33,33	54,17	25,00	37,50	62,50	31,67	30,00
4 Kat	72,08	33,33	37,50	78,33	30,00	37,08	87,50	44,58	36,67
8 Kat	78,12	33,33	35,00	81,04	35,00	36,87	87,08	57,08	40,42
16 Kat	81,67	39,06	40,52	86,46	42,39	43,23	91,87	64,58	41,46
70 – 30 Hold Out									
Orijinal	27,78	13,89	16,67	33,33	16,67	27,78	55,55	25,00	27,78
2 Kat	43,05	18,05	30,55	61,11	19,44	34,72	66,67	43,05	27,78
4 Kat	77,08	27,78	38,19	84,72	33,33	39,58	90,97	59,72	38,89
8 Kat	85,76	35,42	37,50	87,50	42,71	39,93	90,28	59,37	40,97
16 Kat	84,72	42,88	40,28	92,01	50,87	40,10	94,27	71,70	40,28

Çizelge 7.14'te zaman-frekans alanı özellikleri ile elde edilen, UKDH çıkışının 10 ve aktivasyon fonksiyonun TANH olduğu duruma ait doğruluk oranları yüzdesel olarak gösterilmektedir.

Çizelge 7.15. Zaman-frekans alanında üçüncü yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	48,33	16,67	33,33	53,33	17,50	32,50	56,67	25,83	32,50
2 Kat	56,67	25,42	33,33	61,67	32,50	35,00	72,92	37,08	40,42
4 Kat	79,79	40,62	37,29	81,67	47,71	38,75	87,29	58,75	37,08
8 Kat	84,69	43,23	40,21	87,81	54,79	41,87	89,79	65,00	41,77
16 Kat	92,76	51,67	41,46	93,33	64,17	39,69	92,40	72,60	41,30
10 Fold Cross Validation									
Orijinal	50,83	10,83	30,00	54,17	20,83	30,83	61,67	28,33	30,00
2 Kat	57,08	27,08	33,33	62,08	34,17	35,42	68,75	40,00	35,42
4 Kat	81,25	39,79	38,54	86,04	50,00	41,87	87,50	65,21	41,46
8 Kat	86,35	43,44	39,58	88,96	55,62	40,94	89,48	69,90	41,87
16 Kat	93,65	54,17	42,55	92,86	64,11	42,92	93,02	75,21	42,50
50 – 50 Hold Out									
Orijinal	41,67	16,67	28,33	45,00	15,00	26,67	48,33	31,67	28,33
2 Kat	55,83	19,17	31,67	57,50	26,67	32,50	65,83	30,83	33,33
4 Kat	78,33	32,50	37,50	82,08	37,08	35,83	87,50	42,50	36,67
8 Kat	82,29	34,37	39,58	84,17	35,00	39,37	87,92	64,58	41,46
16 Kat	88,54	45,00	42,60	91,46	54,06	40,83	89,69	72,08	40,94
70 – 30 Hold Out									
Orijinal	36,11	16,67	27,78	38,89	19,44	27,78	50,00	30,56	30,56
2 Kat	62,50	18,05	30,55	63,89	20,83	33,33	70,83	31,94	41,67
4 Kat	84,03	38,19	37,50	84,03	47,22	38,19	91,67	56,25	38,89
8 Kat	87,85	40,97	39,58	88,89	54,51	38,54	89,93	67,36	40,28
16 Kat	92,01	50,87	39,41	93,05	51,39	39,41	93,75	73,96	40,28

Çizelge 7.15'te zaman-frekans alanı özellikleri ile elde edilen, UKDH çıkışının 100 ve aktivasyon fonksiyonun TANH olduğu duruma ait doğruluk oranları yüzdesel olarak gösterilmektedir.

Çizelge 7.16. Zaman-Frekans alanında DVM kullanılarak elde edilen doğruluk oranları (%).

Giriş Sayısı	5 Fold Cross Validation			10 Fold Cross Validation		
	minmax	z-score	normal	minmax	z-score	normal
Orijinal	47,50	17,50	30,83	50,00	18,33	30,00
2 Kat	63,33	21,67	33,75	62,50	26,67	33,33
4 Kat	81,04	24,37	31,87	82,50	23,96	32,08
8 Kat	86,15	26,77	31,15	86,56	26,98	31,35
16 Kat	90,26	31,72	31,67	90,42	31,41	31,93
	50 – 50 hold Out			70 – 30 hold Out		
Orijinal	40,00	23,33	26,67	33,33	19,44	25,00
2 Kat	54,17	23,33	20,83	63,89	25,00	26,39
4 Kat	70,42	23,33	27,50	80,55	25,00	22,92
8 Kat	81,67	26,87	30,83	87,50	27,78	35,42
16 Kat	89,69	25,00	29,69	88,19	24,48	30,73

Çizelge 7.17. Zaman-frekans alanında elde edilen en iyi sonuçların hata matrisleri.

	Birinci Yöntem (%92,01)				İkinci Yöntem (%94,27)				Üçüncü Yöntem (%93,75)				DVM (%90,42)			
	a	b	c	d	a	b	c	d	a	b	c	d	a	b	c	d
A=0	121	0	1	0	121	0	1	0	121	1	0	0	473	6	0	1
B=1	4	143	5	0	4	148	0	0	4	148	0	0	14	452	11	3
C=2	1	0	137	14	1	0	144	7	2	0	133	17	3	6	432	39
D=3	3	0	18	129	5	0	15	130	7	0	5	138	5	3	93	379

Çizelge 7.18. Zaman-frekans alanında elde edilen en iyi sonuçların ortalama değerleri.

	TPR	FPR	Precision	Recall	F Measure	MCC	ROC Area	PRC Area
Birinci Yöntem	0,920	0,027	0,922	0,920	0,920	0,893	0,987	0,970
İkinci Yöntem	0,943	0,019	0,944	0,943	0,942	0,924	0,991	0,982
Üçüncü Yöntem	0,938	0,020	0,940	0,938	0,937	0,917	0,993	0,986
DVM	0,904	0,032	0,907	0,904	0,904	0,873	0,962	0,866

Zaman-frekans alanında DVM ile elde edilen sonuçlar Çizelge 7.16’da, en iyi sonuçlara ait hata matrisleri Çizelge 7.17’de, ortalama değerler ise Çizelge 7.18’de gösterilmektedir.

7.4 Bütün Özellikler ile Elde Edilen Sonuçlar

Bu bölümde zaman, frekans ve zaman-frekans alanlarında çıkarılan bütün özellikler kullanılarak elde edilen sonuçlar gösterilmektedir.

Çizelge 7.19. Tüm özelliklerden birinci yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	45,00	25,00	57,50	48,33	24,16	54,16	53,33	32,50	68,33
2 Kat	72,92	34,16	67,50	71,66	35,00	76,66	83,33	38,33	79,16
4 Kat	93,54	39,58	78,33	96,46	48,54	83,33	96,04	55,62	81,45
8 Kat	97,81	50,10	83,75	97,92	57,18	86,25	97,70	65,31	86,56
16 Kat	98,96	57,34	87,92	99,06	64,74	89,53	99,01	79,48	90,05
10 Fold Cross Validation									
Orijinal	50,00	25,00	58,33	50,00	23,33	59,16	54,16	29,16	70,00
2 Kat	74,58	33,75	70,00	71,25	32,92	77,92	84,16	42,50	77,08
4 Kat	94,79	41,04	79,17	96,87	53,75	84,79	97,08	56,25	82,92
8 Kat	97,92	50,62	85,21	98,02	59,58	87,39	98,22	69,48	86,98
16 Kat	99,11	61,35	89,01	99,16	67,03	90,26	98,12	79,63	90,94
50 – 50 Hold Out									
Orijinal	40,00	28,33	43,33	30,00	26,66	35,00	30,00	30,00	36,66
2 Kat	70,00	25,00	60,00	62,50	24,16	49,16	75,00	24,16	78,33
4 Kat	87,08	32,92	67,08	93,75	37,50	80,00	96,66	44,58	82,08
8 Kat	94,17	45,42	76,87	95,83	48,75	80,83	97,08	57,50	79,37
16 Kat	98,75	52,08	83,85	98,75	61,04	88,75	98,54	75,62	88,43
70 – 30 Hold Out									
Orijinal	55,55	33,33	58,33	25,00	16,66	63,88	47,22	30,55	80,55
2 Kat	76,39	30,55	62,50	63,88	29,16	65,28	83,33	36,11	79,16
4 Kat	97,92	38,19	77,78	97,92	45,14	79,86	97,22	58,33	86,80
8 Kat	94,79	48,61	80,55	96,87	61,11	86,46	96,18	70,48	87,15
16 Kat	98,26	55,73	86,63	98,78	63,02	89,93	97,74	73,09	90,45

Çizelge 7.19’da tüm özellikler ile elde edilen, UKDH çıkışının 10 ve aktivasyon fonksiyonunun ReLU olduğu duruma ait doğruluk oranları yüzdesel olarak gösterilmektedir.

Çizelge 7.20. Tüm özelliklerden ikinci yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	62,50	25,83	61,67	45,00	26,67	68,33	62,50	30,00	70,00
2 Kat	75,83	36,67	70,42	80,00	38,33	77,50	82,08	44,17	81,25
4 Kat	93,12	44,79	80,62	97,29	54,58	84,37	96,67	63,33	86,04
8 Kat	97,92	53,44	83,54	98,44	67,60	87,81	98,02	70,83	87,81
16 Kat	98,80	64,11	88,02	98,96	76,41	91,09	98,85	81,41	91,09
10 Fold Cross Validation									
Orijinal	65,00	26,67	65,83	52,50	30,83	70,83	74,17	30,83	72,50
2 Kat	75,42	36,25	74,16	81,25	36,67	79,17	84,17	39,17	82,92
4 Kat	93,75	48,54	81,87	97,08	58,54	86,04	96,87	62,08	86,46
8 Kat	98,12	55,21	85,62	98,54	66,56	88,75	98,26	73,54	88,44
16 Kat	99,01	66,72	89,48	99,22	77,29	91,67	99,27	82,19	91,82
50 – 50 Hold Out									
Orijinal	48,33	30,00	55,00	28,33	23,33	41,67	50,00	23,33	48,33
2 Kat	75,00	25,83	65,00	66,67	25,00	66,67	65,83	22,50	76,67
4 Kat	90,83	35,42	75,00	95,42	35,83	79,58	96,67	46,25	82,92
8 Kat	95,00	46,67	78,96	96,46	56,25	84,17	96,67	60,21	85,42
16 Kat	97,18	54,58	84,16	98,75	71,46	88,96	98,54	77,08	89,48
70 – 30 Hold Out									
Orijinal	52,78	30,55	61,11	36,11	16,67	50,00	58,33	27,78	72,22
2 Kat	79,16	29,16	66,67	79,17	31,94	69,44	80,55	31,94	80,55
4 Kat	92,36	46,53	78,47	96,53	56,25	85,42	97,92	58,33	88,89
8 Kat	95,14	55,56	82,64	96,87	66,67	87,15	96,53	68,40	88,19
16 Kat	98,44	60,42	86,46	98,61	72,92	91,32	97,74	76,04	90,80

Çizelge 7.20’de tüm özellikler ile elde edilen, UKDH çıkışının 10 ve aktivasyon fonksiyonunun TANH olduğu duruma ait doğruluk oranları yüzdesel olarak gösterilmektedir.

Çizelge 7.21. Tüm özelliklerden üçüncü yöntem kullanılarak elde edilen doğruluk oranları (%).

	2 Katman			3 Katman			5 Katman		
5 Fold Cross Validation									
Giriş Sayısı	minmax	z-score	normal	minmax	z-score	normal	minmax	z-score	normal
Orijinal	73,33	28,33	75,83	74,17	28,33	76,67	77,50	31,67	80,83
2 Kat	85,00	44,17	85,83	86,67	47,92	85,42	86,67	49,17	84,17
4 Kat	98,33	65,42	88,33	98,33	70,42	87,92	98,12	72,50	87,71
8 Kat	98,85	73,75	89,27	98,44	80,31	89,68	97,92	79,53	88,75
16 Kat	99,27	84,95	91,93	99,43	89,58	92,34	99,11	88,80	91,15
10 Fold Cross Validation									
Orijinal	76,67	26,67	77,50	79,17	32,50	79,17	80,00	36,67	83,33
2 Kat	84,58	44,17	85,00	90,42	46,25	85,00	90,42	50,83	85,83
4 Kat	98,33	67,50	86,87	98,54	75,00	88,33	98,33	73,75	87,29
8 Kat	98,96	76,67	91,35	98,96	83,96	90,73	97,39	81,77	87,92
16 Kat	99,53	86,87	92,92	99,53	92,45	93,02	98,85	90,62	91,51
50 – 50 Hold Out									
Orijinal	56,67	33,33	76,67	68,33	31,67	73,33	56,67	31,67	83,33
2 Kat	78,33	29,17	75,83	85,83	35,00	80,83	88,33	41,67	85,83
4 Kat	97,92	45,00	87,50	97,92	55,00	87,92	97,92	52,50	87,50
8 Kat	97,71	67,71	84,79	97,92	74,58	85,62	97,50	69,37	85,00
16 Kat	99,17	79,37	90,42	98,96	88,75	90,94	98,64	86,25	91,77
70 – 30 Hold Out									
Orijinal	66,67	19,44	83,33	77,78	25,00	80,55	72,22	27,78	83,33
2 Kat	86,11	34,72	79,17	90,28	43,05	81,94	91,67	48,61	83,33
4 Kat	97,92	59,03	89,58	97,92	68,75	87,50	98,61	68,05	91,67
8 Kat	97,57	70,83	88,89	96,87	79,51	89,58	95,49	77,43	90,27
16 Kat	99,13	82,98	93,23	99,30	91,15	92,88	98,26	87,85	90,10

Çizelge 7.21’de tüm özellikler ile elde edilen, UKDH çıkışının 100 ve aktivasyon fonksiyonunun TANH olduğu duruma ait doğruluk oranları yüzdesel olarak gösterilmektedir.

Çizelge 7.22. Tüm özelliklerden DVM yöntemi kullanılarak elde edilen doğruluk oranları (%).

Giriş Sayısı	5 Fold Cross Validation			10 Fold Cross Validation		
	minmax	z-score	normal	minmax	z-score	normal
Orijinal	71,67	16,67	73,33	74,17	9,16	74,17
2 Kat	80,41	20,42	82,92	80,83	12,08	81,67
4 Kat	96,45	21,25	85,20	96,87	16,67	84,58
8 Kat	97,92	24,79	84,37	97,81	20,73	83,96
16 Kat	98,54	25,05	85,57	98,70	22,92	85,88
	50 – 50 hold Out			70 – 30 hold Out		
Orijinal	55,00	20,00	48,33	63,88	5,55	72,22
2 Kat	81,67	21,67	75,00	87,50	16,67	75,00
4 Kat	97,92	22,50	83,75	97,92	25,00	84,72
8 Kat	97,08	28,54	79,79	95,83	19,10	81,94
16 Kat	98,43	30,10	85,00	97,92	23,78	86,28

Çizelge 7.22’de, tüm özelliklerden DVM aracılığıyla elde edilen doğruluk oranları gösterilmektedir.

Çizelge 7.23. Tüm özelliklerde elde edilen en iyi sonuçların hata matrisleri.

	Birinci Yöntem (%99,16)				İkinci Yöntem (%99,27)				Üçüncü Yöntem (%99,53)				DVM (%98,70)			
	a	b	c	d	a	b	c	d	a	b	c	d	a	b	c	d
A=0	476	2	2	0	478	2	0	0	478	1	0	1	479	0	0	1
B=1	2	474	3	1	2	474	4	0	3	477	0	0	4	469	5	2
C=2	1	0	477	2	0	0	476	4	1	0	478	1	1	0	472	7
D=3	0	0	3	477	0	1	1	478	1	1	0	478	1	0	4	475

Çizelge 7.24. Tüm özelliklerde elde edilen en iyi sonuçların ortalama değerleri.

	TPR	FPR	Precision	Recall	F Measure	MCC	ROC Area	PRC Area
Birinci Yöntem	0,992	0,003	0,992	0,992	0,992	0,989	0,999	0,996
İkinci Yöntem	0,993	0,002	0,993	0,993	0,993	0,990	1	0,999
Üçüncü Yöntem	0,995	0,002	0,995	0,995	0,995	0,994	1	0,999
DVM	0,987	0,004	0,987	0,987	0,987	0,983	0,994	0,980

Tüm özellikler ile elde edilen en iyi sonuçlara ait hata matrisleri Çizelge 7.23'te, ortalama değerler ise Çizelge 7.24'te gösterilmektedir.

Çizelge 7.25. Sınıflandırma işlemi için ölçülen ortalama işlem süreleri (saniye).

Birinci Yöntem (UKDH:10 ReLU)												
	2 Katman				3 Katman				5 Katman			
Giriş Sayısı	5 CV	10 CV	%50	%70	5 CV	10 CV	%50	%70	5 CV	10 CV	%50	%70
Orijinal	3,93	9,4	1,21	1,36	4,2	8,5	1,26	1,5	5,65	11,3	1,7	2,12
2 Kat	7,05	15,7	2,1	2,4	7,75	15,2	2,3	2,6	10,5	21,2	3,1	3,6
4 Kat	13,5	26,2	3,96	4,5	14,7	29,5	4,4	5,3	20,15	39,8	6,1	6,8
8 Kat	25,8	52,3	7,78	8,8	28,5	57,3	8,67	9,62	43,1	86,4	13,1	14,8
16 Kat	51,4	102	15,8	17,3	57,4	112,9	16,9	19,3	88,35	164	25,1	27,8
İkinci Yöntem (UKDH:10 TANH)												
	2 Katman				3 Katman				5 Katman			
Orijinal	3,95	9,1	1,2	1,28	4,36	8,45	1,25	1,6	6,1	11,2	1,65	2,35
2 Kat	7,05	14,8	1,95	2,35	8,1	14,8	2,25	2,8	10	20,75	3,2	3,5
4 Kat	13,5	25,7	3,95	4,6	15,2	29,67	5,1	5,5	21,5	38,5	6	6,5
8 Kat	25,8	51,65	7,65	8,35	29,3	58,35	8,3	10	42,8	85	12,8	15
16 Kat	52	100,5	15,3	16,5	58,6	115,3	17,5	20,1	87,65	165	26	28,3
Üçüncü Yöntem (UKDH:100 TANH)												
	2 Katman				3 Katman				5 Katman			
Orijinal	6,7	13,8	2,1	2,4	9	17,4	2,64	3,2	10,2	20	2,82	3,4
2 Kat	12,6	26,9	3,94	4,5	17,1	35	5,2	5,6	19,25	38,3	5,7	6,6
4 Kat	25,5	50,4	7,7	8,98	33,2	64,6	9,8	11,3	36,6	73,5	10,9	12,4
8 Kat	50,3	99,3	15,9	17,8	64,3	130	19,3	22	75,6	146,5	21,9	24,6
16 Kat	109	216,5	30,7	36,2	129	257	39,3	43,3	155	296,8	43,7	49,9

Sınıflandırma işlemleri sırasında ölçülen işlem sürelerinin ortalaması Çizelge 7.25'te verilmektedir. Özellik sayısındaki değişiklik işlem süresini minimal ölçüde etkilediği için, ölçülen işlem sürelerinin ortalaması alınıp tek grafik halinde verilmektedir.

8. SONUÇ VE ÖNERİLER

Sadece zaman alanı özellikleri kullanılarak yapılan sınıflandırma işlemleri sonucunda elde edilen en yüksek doğruluk oranı %94,27 olmaktadır. Bu oranı elde edebilmek için UKDH katmanının çıkış sayısı 10 olarak belirlenmektedir ve katmanlarda kullanılan aktivasyon fonksiyonu TANH fonksiyonudur. Ayrıca 5 katmanlı YSA yapısı, min-max normalizasyon işlemi uygulanması ve işlemlerin 5 fold cross validation yöntemi ile gerçekleştirilmesi gerekmektedir. UKDH katmanının çıkış sayısı 100 yapıldığında doğruluk oranı %92,66'ya düşmektedir. Bu özellikler ile yapılan sınıflandırma işlemleri sonucunda, DVM ile en yüksek doğruluk oranı %84,58 olarak elde edilmektedir. Bu çalışmada önerilen UKDH yapısının verimi DVM ile karşılaştırıldığında, önerilen yapının daha iyi sonuç verdiği açıkça görülmektedir.

Sadece frekans alanı özellikleri kullanılarak yapılan sınıflandırma işlemleri sonucunda elde edilen en yüksek doğruluk oranı %92,34 olmaktadır. Bu oranı elde edebilmek için UKDH katmanının çıkış sayısı 100 olarak belirlenmektedir ve katmanlarda kullanılan aktivasyon fonksiyonu TANH fonksiyonudur. Ayrıca 5 katmanlı YSA yapısı, min-max normalizasyon işlemi uygulanması ve işlemlerin 10 fold cross validation yöntemi ile gerçekleştirilmesi gerekmektedir. UKDH katmanının çıkış sayısının artması ve aktivasyon fonksiyonunun değişmesi ile doğruluk oranı lineer olarak artmaktadır. Bu özellikler ile yapılan sınıflandırma işlemleri sonucunda, DVM ile en yüksek doğruluk oranı %80,90 olarak elde edilmektedir. Önerilen yapının verimi DVM ile karşılaştırıldığında, önerilen yapının daha iyi sonuç verdiği açıkça görülmektedir. Sadece frekans alanı özelliklerini kullanmak, sadece zaman alanı özelliklerini kullanma durumuna göre daha düşük doğruluk oranı sunmaktadır.

Sadece zaman-frekans alanı özellikleri kullanılarak yapılan sınıflandırma işlemleri sonucunda elde edilen en yüksek doğruluk oranı %94,27 olmaktadır. Bu oranı elde edebilmek için UKDH katmanının çıkış sayısı 10 olarak belirlenmektedir ve katmanlarda kullanılan aktivasyon fonksiyonu TANH fonksiyonudur. Ayrıca 5 katmanlı YSA yapısı, min-max normalizasyon işlemi uygulanması ve işlemlerin

%70-30 hold out yöntemi ile gerçekleştirilmesi gerekmektedir. UKDH katmanının çıkış sayısı 100 yapıldığında doğruluk oranı %93,75'e düşmektedir. Bu özellikler ile yapılan sınıflandırma işlemleri sonucunda, DVM ile en yüksek doğruluk oranı %90,42 olarak elde edilmektedir. Önerilen yapının verimi DVM ile karşılaştırıldığında, önerilen yapının daha iyi sonuç verdiği açıkça görülmektedir. Sadece zaman-frekans alanı özellikleri kullanıldığında sonuçlar zaman alanı özellikleri kullanıldığı duruma benzer çıkmaktadır.

Çıkarılan bütün özelliklerin kullanılması ile yapılan sınıflandırma işlemleri sonucunda elde edilen en yüksek doğruluk oranı %99,53 olmaktadır. Bu oranı elde edebilmek için UKDH katmanının çıkış sayısı 100 olarak belirlenmektedir ve katmanlarda kullanılan aktivasyon fonksiyonu TANH fonksiyonudur. Ayrıca min-max normalizasyon işlemi uygulanması ve işlemlerin 10 fold cross validation yöntemi ile gerçekleştirilmesi gerekmektedir. Bu alanda hem 2 katmanlı hem de 3 katmanlı YSA yapıları en iyi sonucu vermektedir. Bu özellikler ile yapılan sınıflandırma işlemleri sonucunda, DVM ile en yüksek doğruluk oranı %98,27 olarak elde edilmektedir. Önerilen yapının verimi DVM ile karşılaştırıldığında, önerilen yapının daha iyi sonuç verdiği açıkça görülmektedir. Bütün özellikler kullanıldığında, her 3 yöntem ile de %99 ve üzeri sonuçlar elde edilebilmektedir.

Yapılan işlemler sonucunda, tanh aktivasyon fonksiyonu ile daha yüksek doğruluk oranları elde edilmektedir. Burada gösterilen relu ve tanh aktivasyon fonksiyonları haricinde diğer fonksiyonlar ile elde edilen doğruluk oranları daha düşük olmaktadır.

Veri sayısındaki artış, sonucu doğrudan pozitif oranda etkilemektedir. Bu da önerilen yapının verimli olduğunu, ancak veri sayısı artırılmadığı sürece yüksek doğruluk oranları elde edilemediğini göstermektedir. Ayrıca veri sayısını 16 kattan daha fazla artırmanın gereksiz iş yükü olacağı görülmektedir.

Doğruluk oranları incelendiğinde açıkça görülmektedir ki normalizasyon yöntemleri arasında en iyi sonucu veren yöntem min-max normalizasyondur. Elde edilen sonuçlar göstermektedir ki; z-score normalizasyon yöntemi ile yüksek doğruluk oranları elde edebilmek için veri sayısının çok fazla olması gerekmektedir.

Normalizasyon yapılmadığı durumda yüksek doğruluk oranları elde edilememektedir.

Özellik sayısındaki artış veya azalış işlem süresini etkilememektedir. Deneysel sonuçlar bölümünde görülebileceği gibi, katman sayısı arttıkça işlem süresi kayda değer miktarda artmaktadır. Aynı şekilde giriş verisinin sayısı işlem süresini doğrudan etkilemektedir ve UKDH katmanının çıkış sayısı arttıkça işlem süresi artmaktadır. UKDH katmanının çıkış sayısı 1000 ve üzeri yapılarak denemeler yapılmış ve işlem süresinin yaklaşık 50 kat artmasına rağmen doğruluk oranının değişmediği gözlemlenmiştir.



9. KAYNAKLAR

- Abu-Mahfouz I (2003) “Drilling Wear Detection and Classification Using Vibration Signals and Artificial Neural Network”, *International Journal of Machine Tools and Manufacture*, 43(7): 707-720.
- Abu-Mahfouz I (2005) “A Comparative Study of Three Artificial Neural Networks For the Detection and Classification of Gear Faults”, *International Journal of General Systems*, 34(3): 261-277.
- Ali JB, Fnaiech N, Saidi L, Chebel-Morello B & Fnaiech F (2015) “Application of Empirical Mode Decomposition and Artificial Neural Network For Automatic Bearing Fault Diagnosis Based on Vibration Signals”, *Applied Acoustics*, 89: 16-27.
- Aliustaoğlu C, Ocak H & Ertunç HM (2007) “Rulman Titreşim Analizi ile Bölgesel Hataların İncelenmesi”, *TOK'07 Bildiriler Kitabı*, 5-7 Eylül 2007, İstanbul.
- Altın C & Er O (2016) “Comparison of Different Time and Frequency Domain Feature Extraction Methods On Elbow Gesture’s EMG”, *European journal of interdisciplinary studies*, 2(3): 35-44.
- Altintas Y (2012) “Manufacturing Automation: Metal Cutting Mechanics, Machine Tool Vibrations, and CNC Design”, *Cambridge University Press*, Cambridge England
- Ayaz E & Şeker S (2002) “İleri İşaret İşleme Yöntemleri ile Elektrik Motorlarında Rulman Arıza Tanısı”, *İTÜDERGİSİ/d*, 1 (1).
- Baccouche M, Mamalet F, Wolf C, Garcia C & Baskurt A (2011) “Sequential Deep Learning For Human Action Recognition”, In *International workshop on human behavior understanding* (pp. 29-39), 16 November 2011, Berlin, Heidelberg.
- Baydar N & Ball A (2001) “A Comparative Study of Acoustic and Vibration Signals in Detection of Gear Failures Using Wigner–Ville Distribution”, *Mechanical Systems and Signal Processing*, 15(6): 1091-1107.
- Baydar N & Ball A (2003) “Detection of Gear Failures Via Vibration and Acoustic Signals Using Wavelet Transform”, *Mechanical Systems and Signal Processing*, 17(4): 787-804.
- Bellini A, Immovilli F, Rubini R & Tassoni C (2008) “Diagnosis of Bearing Faults of Induction Machines by Vibration or Current Signals: A Critical Comparison”, In *2008 IEEE Industry Applications Society Annual Meeting* (pp. 1-8), 5-9 October 2008, Edmonton Alberta Canada.
- Bin GF, Gao JJ, Li XJ & Dhillon BS (2012) “Early Fault Diagnosis of Rotating Machinery Based on Wavelet Packets — Empirical Mode Decomposition

- Feature Extraction and Neural Network”, *Mechanical Systems and Signal Processing*, 27: 696-711.
- Breuel TM, Ul-Hasan A, Al-Azawi MA & Shafait F (2013) “High-Performance OCR For Printed English and Fraktur Using LSTM Networks”, In 2013 12th International Conference on Document Analysis and Recognition (pp. 683-687), 25-28 August 2013, Washington DC USA.
- Cartwright KV (2007) “Determining the Effective or RMS Voltage of Various Waveforms Without Calculus” *The Technology Interface*, 8 (1): 1-20.
- Cerrada M, Sánchez R, Cabrera D, Zurita G & Li C (2015) “Multi-Stage Feature Selection by Using Genetic Algorithms For Fault Diagnosis In Gearboxes Based on Vibration Signal”, *Sensors*, 15(9): 23903-23926.
- Chang CC & Lin CJ (2011) “LIBSVM: A Library For Support Vector Machines”, *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2 (3): 27.
- Chatzimisios P, Verikoukis C, Santamaría I, Laddomada M & Hoffmann O (2010) “Mobile Lightweight Wireless Systems”, Second International ICST Conference, May 10-12 2010, Barcelona Spain.
- Cho K, Van Merriënboer B, Gulcehre C, Bahdanau D, Bougares F, Schwenk H & Bengio Y (2014) “Learning phrase Representations Using RNN Encoder-Decoder For Statistical Machine Translation”, arXiv preprint arXiv : 1406.1078.
- Choi E, Schuetz A, Stewart WF & Sun J (2016) “Using Recurrent Neural Network Models For Early Detection of Heart Failure Onset”, *Journal of the American Medical Informatics Association*, 24(2): 361-370.
- Chowdhury R, Reaz M, Ali M, Bakar A, Chellappan K & Chang T (2013) “Surface Electromyography Signal Processing and Classification Techniques”, *Sensors*, 13(9): 12431-12466.
- Cornia M, Baraldi L, Serra G & Cucchiara R (2018) “Predicting Human Eye Fixations Via an LSTM-Based Saliency Attentive Model”, *IEEE Transactions on Image Processing*, 27(10): 5142-5154.
- Cristianini N & Shawe-Taylor J (2000) *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*, Cambridge university press, Cambridge England.
- Çayıroğlu İ (2015) İleri Algoritma Analizi-5 Yapay Sinir Ağları, <http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf>, 10.04.2019
- Dal H, Morgül Ö & Şahin İ (2006) “Yapay Sinir Agi (YSA) Kullanarak Titreşim Tabanlı Makina Durum İzlemesi ve Hata Teşhisi”, *Sakarya University Journal of Science*, 10(2): 45-50.
- Dalpiazz G, Rivola A & Rubini R (2000) “Effectiveness and Sensitivity of Vibration Processing Techniques For Local Fault Detection in Gears”, *Mechanical systems and signal processing*, 14(3): 387-412.

- De Bruin T, Verbert K & Babuška R (2016) “Railway Track Circuit Fault Diagnosis Using Recurrent Neural Networks”, *IEEE transactions on neural networks and learning systems*, 28(3): 523-533.
- Deng L & Yu D (2014) “Deep Learning: Methods and Applications”, *Foundations and Trends® in Signal Processing*, 7(3–4): 197-387.
- Dong C, Loy CC, He K & Tang X (2014) “Learning a Deep Convolutional Network For Image Super-Resolution”, *European conference on computer vision*, 6-12 September 2014, Zurich Switzerland.
- Dou D & Zhou S (2016) “Comparison of Four Direct Classification Methods For Intelligent Fault Diagnosis of Rotating Machinery”, *Applied Soft Computing*, 46: 459-468.
- El-Wardany TI, Gao D & Elbestawi MA (1996) “Tool Condition Monitoring in Drilling Using Vibration Signature Analysis”, *International Journal of Machine Tools and Manufacture*, 36(6): 687-711.
- Elbhah K & Sinha JK (2013) “Vibration-Based Condition Monitoring of Rotating Machines Using a Machine Composite Spectrum”, *Journal of Sound and Vibration*, 332(11): 2831-2845.
- Ertekin Z, Özkurt N & Yilmaz C (2017) “Disk Fren Sistemlerinde Dalgacık Tepeleri Yöntemi ile Ses Analizi”, *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 32(4): 193-200.
- Ertunc HM & Oysu C (2004) “Drill Wear Monitoring Using Cutting Force Signals”, *Mechatronics*, 14(5): 533-548.
- Fan X & Zuo MJ (2006) “Gearbox Fault Detection Using Hilbert and wavelet Packet Transform”, *Mechanical systems and Signal processing*, 20(4): 966-982.
- Fan Y, Qian Y, Xie FL & Soong FK (2014) “TTS Synthesis with Bidirectional LSTM Based Recurrent Neural Networks”, *In Fifteenth Annual Conference of the International Speech Communication Association*, 14-18 September 2014, Singapore.
- Farley B & Clark W (1954) “Simulation of Self-Organizing Systems by Digital Computer”, *Transactions of the IRE Professional Group on Information Theory*, 4(4): 76-84.
- Fidan H (2006) *Dalgacık Dönüşümü Tekniği ile Motor Arıza Tespiti*, Doktora Tezi, SDÜ Fen Bilimleri Enstitüsü, Sakarya.
- Fukushima K (1980) “Neocognitron: A Self-Organizing Neural Network Model For a Mechanism of Pattern Recognition Unaffected by Shift in Position”, *Biological cybernetics*, 36(4): 193-202.
- Gan M & Wang C (2016) “Construction of Hierarchical Diagnosis Network Based on Deep Learning and Its Application in the Fault Pattern Recognition of Rolling Element Bearings”, *Mechanical Systems and Signal Processing*, 72: 92-104.

- Gers FA & Schmidhuber J (2000) "Recurrent Nets That Time and Count", IEEE-INNS- ENNS International Joint Conference on Neural Networks (IJCNN 2000) Neural Computing: New Challenges and Perspectives for the New Millennium (Vol. 3, pp. 189-194), 24-27 July 2000, Italy.
- Glorot X, Bordes A & Bengio Y (2011) "Domain adaptation for Large-Scale Sentiment Classification: A Deep Learning Approach" 28th international conference on machine learning (ICML-11) (pp. 513-520), June 28-July 2 2011, Bellevue Washington USA.
- Goumas SK, Zervakis ME & Stavrakakis GS (2002) "Classification of washing Machines Vibration Signals Using Discrete Wavelet Analysis For Feature Extraction", IEEE Transactions on Instrumentation and Measurement, 51(3): 497-508.
- Graves A & Schmidhuber J (2005) "Framewise Phoneme Classification with Bidirectional LSTM and Other Neural Network Architectures", Neural Networks, 18(5-6): 602-610.
- Greff K, Srivastava RK, Koutník J, Steunebrink BR & Schmidhuber J (2016) "LSTM: A Search Space Odyssey", IEEE transactions on neural networks and learning systems, 28(10): 2222-2232.
- Haykin S (2004) "Neural Networks: A Comprehensive Foundation", Neural networks, 2(2004): 41.
- Henao H, Kia SH & Capolino GA (2011) "Torsional-vibration assessment and Gear-Fault Diagnosis in Railway Traction System", IEEE transactions on industrial electronics, 58(5): 1707-1717.
- Hubel DH & Wiesel TN (1963) "Shape and Arrangement of Columns in Cat's Striate Cortex", The Journal of physiology, 165(3): 559-568.
- Isermann R & Balle P (1997) "Trends in the Application of Model-Based Fault Detection and Diagnosis of Technical Processes", Control engineering practice, 5(5): 709-719.
- Jafari SM, Mehdigholi H & Behzad M (2014) "Valve Fault Diagnosis in Internal Combustion Engines Using Acoustic Emission and Artificial Neural Network", Shock and Vibration, 2014.
- Janssens O, Slavkovikj V, Vervisch B, Stockman K, Loccufier M, Verstockt S, deWalle RV & Van Hoescke S (2016) "Convolutional Neural Network Based Fault Detection For Rotating Machinery", Journal of Sound and Vibration, 377: 331-345.
- Jardine AK, Lin D & Banjevic D (2006) "A Review on Machinery Diagnostics and Prognostics Implementing Condition-Based Maintenance", Mechanical systems and signal processing, 20(7): 1483-1510.
- Jing L, Zhao M, Li P & Xu X (2017) "A Convolutional Neural Network Based Feature Learning and Fault Diagnosis Method For the Condition Monitoring of Gearbox", Measurement, 111: 1-10.

- Jozefowicz R, Zaremba W & Sutskever I (2015) “An Empirical Exploration of Recurrent Network Architectures”, International Conference on Machine Learning, 6–11 July 2015, France.
- Jung U & Koh BH (2015) “Wavelet Energy-Based Visualization and Classification of High-Dimensional Signal For Bearing Fault Detection”, *Knowledge and Information Systems*, 44(1): 197-215.
- Kanai M & Kanda Y (1978) "Statistical Characteristics of Drill Wear and Drill Life For the Standardized Performance Tests", *Annals of CIRP*, 27(1): 61-66.
- Kapur R (2017) Recurrent Neural Networks & LSTMs, <https://ayearofai.com/rohan-lenny-3-recurrent-neural-networks-10300100899b>, 05.03.2019
- Karpathy A (2015) The Unreasonable Effectiveness of Recurrent Neural Networks, <https://karpathy.github.io/2015/05/21/rnn-effectiveness/>, 01.03.2019
- Kiranyaz S, Gastli A, Ben-Brahim L, Alemadi N & Gabbouj M (2018) “Real-Time Fault Detection and Identification For Mmc Using 1D Convolutional Neural Networks”, *IEEE Transactions on Industrial Electronics*,
- Krizhevsky A, Sutskever I & Hinton GE (2012) “Imagenet Classification with Deep Convolutional Neural Networks”, In *Advances in neural information processing systems*: 1097-1105.
- Koutnik J, Greff K, Gomez F & Schmidhuber J (2014) “A Clockwork RNN”, arXiv preprint arXiv, 1402: 3511.
- Kumar A, Ramkumar J, Verma NK & Dixit S (2014) “Detection and Classification For Faults in Drilling Process Using Vibration Analysis”, *International Conference on Prognostics and Health Management IEEE*, 22 - 25 June 2014, Spokane Washington USA.
- Lang S, Bravo-Marquez F, Beckham C, Hall M & Frank E (2019) “WekaDeeplearning4j: A Deep Learning Package For Weka Based on Deeplearning4j”, *Knowledge-Based Systems*, 10: 1016.
- LeCun Y, Boser B, Denker JS, Henderson D, Howard RE, Hubbard W & Jackel LD (1989) “Backpropagation Applied to Handwritten Zip Code Recognition”, *Neural computation*, 1(4): 541-551.
- LeCun Y, Bottou L, Bengio Y & Haffner P (1998) “Gradient-Based Learning Applied to Document Recognition”, *Proceedings of the IEEE*, 86(11): 2278-2324.
- Lei Y, Jia F, Lin J, Xing S & Ding SX (2016) “An intelligent Fault Diagnosis Method Using Unsupervised Feature Learning Towards Mechanical Big Data”, *IEEE Transactions on Industrial Electronics*, 63(5): 3137-3147.
- Li C, Sánchez RV, Zurita G, Cerrada M & Cabrera D (2016) “Fault Diagnosis For Rotating Machinery Using Vibration Measurement Deep Statistical Feature Learning”, *Sensors*, 16(6), 895.

- Li Z, Yan X, Tian Z, Yuan C, Peng Z & Li L (2013) "Blind Vibration Component Separation and Nonlinear Feature Extraction Applied to the Nonstationary Vibration Signals For the Gearbox Multi-Fault Diagnosis", *Measurement*, 46(1): 259-271.
- Lin J & Zuo MJ (2003) "Gearbox Fault Diagnosis Using Adaptive Wavelet Filter", *Mechanical systems and signal processing*, 17(6): 1259-1269.
- Liu H, Zhou J, Zheng Y, Jiang W & Zhang Y (2018) "Fault Diagnosis of Rolling Bearings with Recurrent Neural Network-Based Autoencoders", *ISA transactions*, 77: 167-178.
- Liu R, Yang B, Zio E & Chen X (2018) "Artificial Intelligence For Fault Diagnosis of Rotating Machinery: A Review", *Mechanical Systems and Signal Processing*, 108: 33-47.
- Masri SF, Smyth AW, Chassiakos AG, Caughey TK & Hunter NF (2000) "Application of Neural Networks For Detection of Changes in Nonlinear Systems", *Journal of Engineering Mechanics*, 126(7): 666-676.
- Malhotra P, Vig L, Shroff G & Agarwal P (2015) "Long Short Term Memory Networks For Anomaly Detection in Time Series", *European Symposium on Artificial Neural Networks - Computational Intelligence and Machine Learning*, 22-24 April 2015, Bruges Belgium.
- McCulloch WS & Pitts W (1943) "A Logical Calculus of the Ideas Immanent in Nervous Activity", *The Bulletin of Mathematical Biophysics*, 5(4): 115-133.
- McInerny SA & Dai Y (2003) "Basic Vibration Signal Processing For Bearing Fault Detection", *IEEE Transactions on Education*, 46(1): 149-156.
- Meltzer G & Dien NP (2004) "Fault Diagnosis in Gears Operating Under Non-Stationary Rotational Speed Using Polar Wavelet Amplitude Maps", *Mechanical Systems and Signal Processing*, 18(5): 985-992.
- Moosavian A, Ahmadi H, Tabatabaeefar A & Khazaei M (2013) "Comparison of Two Classifiers; K-Nearest Neighbor and Artificial Neural Network, For Fault Diagnosis on a Main Engine Journal-Bearing", *Shock and Vibration*, 20(2): 263-272.
- Nembhard AD, Sinha JK & Yunusa-Kaltungo A (2015) "Development of a Generic Rotating Machinery Fault Diagnosis Approach Insensitive to Machine Speed And Support Type", *Journal of Sound and Vibration*, 337: 321-341.
- Nielsen MA (2015) *Neural Networks And Deep Learning*, 25, Determination Press, San Francisco CA USA.
- Olah C (2015) *Understanding LSTM Networks*, <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>, 05.03.2019
- Pandya DH, Upadhyay S & Harsha SP (2012) "Ann Based Fault Diagnosis of Rolling Element Bearing Using Time-Frequency Domain Feature",

- International Journal of Engineering Science and Technology, 4(6): 2878-2886.
- Rafiee J, Rafiee MA & Tse PW (2010) "Application of Mother Wavelet Functions For Automatic Gear and Bearing Fault Diagnosis", *Expert Systems with Applications*, 37(6): 4568-4579.
- Ru-qing C (2005) "Comparison Between Two Fault Diagnosis Methods Based on Neural Network [J] ", *Chinese Society for Electrical Engineering (CSEE)*, 26 June 2005, China.
- Safizadeh MS & Latifi SK (2014) "Using Multi-Sensor Data Fusion For Vibration Fault Diagnosis of Rolling Element Bearings by Accelerometer and Load Cell", *Information Fusion*, 18: 1-8.
- Sakthivel NR, Sugumaran V & Babudevasenapati S (2010) "Vibration Based Fault Diagnosis of Monoblock Centrifugal Pump Using Decision Tree", *Expert Systems with Applications*, 37(6): 4040-4049.
- Samanta B, Al-Balushi KR & Al-Araimi SA (2003) "Artificial Neural Networks and Support Vector Machines with Genetic Algorithm For Bearing Fault Detection", *Engineering applications of artificial intelligence*, 16(7-8): 657-665.
- Samarasinghe HK & Hashimoto S (2000) "Fault detection and Diagnosis System For Air-Conditioning Units Using Recurrent Type Neural Network", 2000 *IEEE international conference on systems, man and cybernetics. cybernetics evolving to systems, humans, organizations, and their complex interactions'*, 8-11 Oct. 2000 Nashville TN USA.
- Saravanan N, Cholairajan S & Ramachandran KI (2009) "Vibration-Based Fault diagnosis of Spur Bevel Gear Box Using Fuzzy Technique", *Expert systems with applications*, 36(2): 3119-3135.
- Seshadrinath J, Singh B & Panigrahi BK (2013) "Investigation of Vibration Signatures For Multiple Fault Diagnosis in Variable Frequency Drives Using Complex Wavelets", *IEEE Transactions on Power Electronics*, 29(2): 936-945.
- Sinha JK & Elbhah K (2013) "A Future Possibility of Vibration Based Condition Monitoring of Rotating Machines", *Mechanical Systems and Signal Processing*, 34(1-2): 231-240.
- Sundermeyer M, Schlüter R & Ney H (2012) "LSTM Neural Networks For Language Modeling", In *Thirteenth annual conference of the international speech communication association*, 9-13 September 2012, Portland, OR, USA.
- Tang T, Xiong M, Liu Y & Li J (1998) "ANN-Based Nonlinear Time Series Models in Fault Detection And Prediction", *International Federation of Automatic Control (IFAC)*, 9-11 November 1998, Gramado Brazil.

- Tkach D, Huang H & Kuiken TA (2010) "Study of Stability of Time-Domain Features For Electromyographic Pattern Recognition", *Journal of neuroengineering and rehabilitation*, 7(1): 21.
- Tse PW & Atherton DP (1999) "Prediction of Machine Deterioration Using Vibration Based Fault Trends and Recurrent Neural Networks", *Journal of vibration and acoustics*, 121(3): 355-362.
- Verma NK, Sevakula R., Dixit S & Salour A (2015) "Data Driven Approach For Drill Bit Monitoring", *IEEE Reliab. Mag*, 19-26.
- Villa LF, Reñones A, Peran JR & de Miguel LJ (2012) "Statistical Fault Diagnosis Based on Vibration Analysis For Gear Test-Bench Under Non-Stationary Conditions of Speed and Load", *Mechanical Systems and Signal Processing*, 29: 436-446.
- Waibel A, Hanazawa T, Hinton G, Shikano K & Lang KJ (1995) "Phoneme Recognition Using Time-Delay Neural Networks", *Backpropagation: Theory, Architectures and Applications*, 35-61.
- Wan X, Wang D, Peter WT, Xu G & Zhang Q (2016) "A Critical Study of Different Dimensionality Reduction Methods For Gear Crack Degradation Assessment Under Different Operating Conditions", *Measurement*, 78: 138-150.
- Wang D (2016) "K-Nearest Neighbors Based Methods For Identification of Different Gear Crack Levels Under Different Motor Speeds and Loads: Revisited", *Mechanical Systems and Signal Processing*, 70: 201-208.
- Wang Y, Xiang J, Markert R & Liang M (2016) "Spectral Kurtosis For Fault Detection, Diagnosis and Prognostics of Rotating Machines: A Review with Applications", *Mechanical Systems and Signal Processing*, 66: 679-698.
- Werbos P (1974) *Beyond Regression: New Tools For Prediction and Analysis in the Behavioral Sciences*, Ph. D. dissertation, Harvard University, Boston USA.
- Widodo A & Yang BS (2007) "Support Vector Machine in Machine Condition Monitoring and Fault Diagnosis", *Mechanical systems and signal processing*, 21(6): 2560-2574.
- Wöllmer M, Metallinou A, Eyben F, Schuller B & Narayanan S (2010) "Context-Sensitive Multimodal Emotion Recognition From Speech and Facial Expression Using Bidirectional LSTM Modeling", In *Proc. INTERSPEECH 2010 11th Annual Conference of the International Speech Communication Association* (pp. 2362-2365), 26-30 September 2010, Makuhari Japan.
- Wu Y, Yuan M, Dong S, Lin L & Liu Y (2018) "Remaining Useful Life Estimation of Engineered Systems Using Vanilla LSTM Neural Networks", *Neurocomputing*, 275: 167-179.
- Xiao X, Zhang S, Mercaldo F, Hu G & Sangaiah AK (2019) "Android Malware Detection Based on System Call Sequences And LSTM", *Multimedia Tools and Applications*, 78(4): 3979-3999.

- Yan R, Gao RX & Chen X (2014) "Wavelets For Fault Diagnosis of Rotary Machines: A Review with Applications", *Signal processing*, 96: 1-15.
- Yang W & Xu X (2008) "Modelling Machine Tool Data in Support of STEP-NC Based Manufacturing", *International Journal of Computer Integrated Manufacturing*, 21(7): 745-763.
- Yao K, Cohn T, Vylomova K, Duh K & Dyer C (2015) "Depth-Gated Recurrent Neural Networks", *arXiv preprint arXiv:1508.03790*, 9.
- Yeşilyurt M, Özcerit AT, Yalman Y & Ertürk İ (2012) "Sayısal İmgeler İçin Ayrık Kosinüs Dönüşümü Esaslı Veri Gizlemenin Ataklara Dayanıklılığı", *Akademik Bilişim Konferansı*, 1 - 3 Şubat 2012, Uşak.
- Yuan M, Wu Y & Lin L (2016) "Fault Diagnosis and Remaining Useful Life Estimation of Aero Engine Using LSTM Neural Network", 2016 IEEE International Conference on Aircraft Utility Systems (AUS), 10-12 October 2016, Beijing China.
- Yunusa-Kaltungo A, Sinha JK & Nembhard AD (2015) "A Novel Fault Diagnosis Technique For Enhancing Maintenance and Reliability of Rotating Machines", *Structural Health Monitoring*, 14(6): 604-621.
- Zhang C, Bengio S, Hardt M, Recht B & Vinyals O (2016) "Understanding Deep Learning Requires Rethinking Generalization", *arXiv preprint arXiv:1611.03530*.
- Zhao R, Yan R, Chen Z, Mao K, Wang P & Gao RX (2019) "Deep Learning and Its Applications to Machine Health Monitoring", *Mechanical Systems and Signal Processing*, 115: 213-237.
- Zhao R, Yan R, Wang J & Mao K (2017) "Learning to Monitor Machine Health with Convolutional Bi-Directional LSTM Networks", *Sensors*, 17(2): 273.
- Zhao R, Wang J, Yan R & Mao K (2016) "Machine Health Monitoring with LSTM Networks", 2016 10th International Conference on Sensing Technology (ICST), 11-13 November 2016, New Zealand Australia.



EKLER

10. EKLER

EK A

Özellik Çıkarmak İçin Kullanılan Matlab Kodu

```
count=1;

for p=1:15

    ini=num2str(p);

    for c=1:2

        if (c==1)

            name=strcat(ini, '.txt');

        else name=strcat(ini, '-1.txt');

        end

    new = textread(name, 'f');

    smnorm=new';

    % Time domain features

    absmean=sum(abs(smnorm))/length(smnorm);

    maxpeak=max(abs(smnorm));

    rms=sqrt((sum(smnorm.^2))/length(smnorm));

    var=sum((smnorm-mean(smnorm)).^2)/(length(smnorm)-1);

    kurt=kurtosis(smnorm);

    crfac=maxpeak/rms;
```

```

sf=rms/abs(mean(smnorm));

skew= skewness(smnorm);

FV_time=[absmean maxpeak rms var kurt crfac sf skew];

% frequency domain features

[H1,f] = freqz(smnorm,1,256,25000);

for i=1:8

    HH(i)=sum(abs(H1((32*(i-1)+1):(32*i))));

    c(i)=HH(i)/sum(abs(H1));

end

for i=1:8

    FV_freq(i)=c(i);

end

clear H1 HH i c f;

% Morlet features

a=16; b=0.02; b1=0.5; a1=0.9;

for t=1:200

    morl(t)=exp(-b1.^2*(t-b).^2/a.^2)*cos(pi*(t-b)/a);

end

clear t;clear a*;clear b*;

morc=conv(smnorm,morl);

clear morl;

```

```
wvf(1)=std(morc);  
  
wvf(2)=entropy(morc);  
  
wvf(3)=kurtosis(morc);  
  
wvf(4)=skewness(morc);  
  
wvf(5)=std(morc).^2;  
  
FV_wave=wvf;  
  
feature(count,1:21)=[FV_time FV_freq FV_wave];  
  
count=count+1;  
  
end  
  
end
```


11. ÖZGEÇMİŞ

Adı Soyadı : Hüseyin Canbaz
Doğum Yeri ve Tarihi : Kızılcahamam 08.06.1992
Lisans Üniversitesi : Bolu Abant İzzet Baysal Üniversitesi
Elektronik posta : huseyin.cnbz@hotmail.com
İletişim Adresi : Çambaşı cad. 290 sok. no:3/16 Keçiören
Ankara

Bilimsel Yayın Listesi

Polat K & Canbaz H (2019) “Fault Detection of CNC Machines from Vibration Signals using Machine Learning methods”, International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAME 2019), 20-21-22 April 2019, Antalya Turkey