



T.C.  
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**DOKTORA TEZİ**

**İNŞAAT SÜRECİNDE İŞÇİ AKTİVİTELERİNİN DERİN  
ÖĞRENME İLE OTOMATİK SINIFLANDIRILMASI**

**Ömür TEZCAN**

**DANIŞMAN**  
**Dr. Öğr. Üyesi Cemil AKÇAY**

**İnşaat Mühendisliği Anabilim Dalı**

**İnşaat Mühendisliği Programı**

**İSTANBUL-2021**

Bu çalışma, 30.03.2021 tarihinde ařağıdaki jüri tarafından İnřaat Mühendisliğı Anabilim Dalı, İnřaat Mühendisliğı Programında Doktora tezi olarak kabul edilmiştir.

### Tez Jürisi

Dr. Öğr. Üyesi Cemil AKÇAY(Danışman)  
İstanbul Üniversitesi  
Mimarlık Fakültesi

Prof. Dr. Ekrem MANİSALI  
Niřantaşı Üniversitesi  
Mühendislik Mimarlık Fakültesi

Prof. Dr. Gül POLAT TATAR  
İstanbul Teknik Üniversitesi  
İnřaat Fakültesi

Prof. Dr. Ümit İŐIKDAĞ  
Mimar Sinan Üniversitesi  
Enformatik Bölümü

Dr. Öğr. Üyesi Ömer GİRAN  
İstanbul Üniversitesi-Cerrahpařa  
Mühendislik Fakültesi



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

## ÖNSÖZ

Ne eksik, ne fazla, ne önce, ne sonra;

Her şey tam zamanında, tam da olması gerektiği gibi,

O'na...

Bu çalışmada katkısı olan herkese en derin teşekkürlerimle;

Mart 2021

Ömür TEZCAN

# İÇİNDEKİLER

Sayfa No

ÖNSÖZ .....	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ .....	vii
TABLO LİSTESİ.....	xi
SİMGE VE KISALTMA LİSTESİ .....	xiii
ÖZET .....	xiv
SUMMARY .....	xv
<b>1. GİRİŞ .....</b>	<b>1</b>
<b>2. GENEL KISIMLAR.....</b>	<b>5</b>
2.1. İNSAN HAREKETLERİ TANIMLAMA VE YAPILAN ÇALIŞMALAR: .....	5
2.1.1. Sensör Tiplerine Göre İnsan Hareketi Tanımlama .....	8
2.1.2. Sensör Kullanılarak Yapılan İnsan Hareketi Tanımlama Çalışmaları .....	9
2.2. İNŞAAT SEKTÖRÜNDE İNSAN HAREKETİ TANIMLAMA .....	13
2.3. YAPAY ZEKA MAKİNE ÖĞRENMESİ .....	18
2.4. DERİN ÖĞRENME .....	20
2.4.1. Tekrarlayan Sinir Ağları (RNN).....	21
2.4.2. Uzun Kısa Süreli Bellek Ağları (LSTM).....	22
2.4.3 Çift Yönlü Uzun Kısa Süreli Bellek Ağları (BiLSTM).....	26
<b>3. MALZEME VE YÖNTEM.....</b>	<b>28</b>
3.1. VERİ TOPLAMA YÖNTEMİ.....	28
3.2. VERİ TOPLAMADA KULLANILAN ARAÇ VE YAZILIMLAR .....	29
3.2.1. Hareket Sensör Verileri Toplanmasında Kullanılan Araç ve Yazılımlar:.....	29
3.2.2. Ses Verileri Toplanmasında Kullanılan Araç ve Yazılımlar .....	31
3.3. TEZ ÇALIŞMASI KAPSAMINDA BELİRLENEN İŞ AKTİVİTELERİ .....	32
3.4. VERİ TOPLAMA SÜRECİ .....	33
3.4.1. Sensör Verilerinin Toplanması .....	34
3.4.2. Ses Verilerinin Toplanması .....	37
3.5. VERİ AKTARIM, ETİKETLEME VE ÖN İŞLEME SÜRECİ .....	38
3.5.1. Sensör Verileri Aktarım ve Ön İşleme .....	39
3.5.2. Ses Verileri Aktarım ve Ön İşleme .....	42

<b>4. BULGULAR.....</b>	<b>47</b>
4.1. SENSÖR VERİLERİ DERİN ÖĞRENME AĞI EĞİTİM .....	48
4.1.1. Sensör İvme Verileri ile Aktivite Tanımlama (ACC) .....	49
4.1.2. Sensör Konum Verileri ile Aktivite Tanımlama (POS) .....	62
4.1.3. Sensör İvme ve Konum Verileri ile Aktivite Tanımlama (ACCPOS) .....	76
4.2. SES VERİLERİ DERİN ÖĞRENME AĞI EĞİTİM.....	91
4.2.1. Sensorlog Ses Verileri ile Aktivite Tahmini .....	91
4.2.2. Ses Kayıt Verileri ile Aktivite Tahmini.....	103
<b>5. TARTIŞMA VE SONUÇ .....</b>	<b>115</b>
<b>6. KAYNAKLAR .....</b>	<b>120</b>
<b>7. EKLER .....</b>	<b>129</b>
<b>8. ÖZGEÇMİŞ .....</b>	<b>130</b>

## ŞEKİL LİSTESİ

	Sayfa No
Şekil 2.1: İnsan hareketi tanımlama süreci.....	5
Şekil 2.2: UCI Smartphone ve Skoda Checkpoint setleri veri toplama görüntüleri ( <i>wiki:dataset [Human Activity/Context Recognition Datasets], 2020; UCI Machine Learning Repository: Smartphone Dataset for Human Activity Recognition (HAR) in Ambient Assisted Living (AAL) Data Set, 2020</i> ) .....	7
Şekil 2.3: Sıva ve boya işine ait sensör verilerinin x,y,z eksenindeki görüntüleri .....	9
Şekil 2.4: Lim ve diğ. (2016) tarafından yapılan üç hareketi tanımlamaya ilişkin çalışma görüntüleri .....	15
Şekil 2.5: Akhavian ve Behzadan (2016) tarafından yapılan hareket tanımlama çalışması görüntüleri .....	15
Şekil 2.6: Akhavian ve Behzadan (2016) tarafından yapılan çalışmanın akış şeması .....	16
Şekil 2.7: Nath ve diğ. (2018) kas sistemi açısından riskli hareketlerin tespit çalışması görüntüleri .....	17
Şekil 2.8: Makine öğrenmesinde kullanılan teknikler ( <i>Introducing Machine Learning, 2020</i> ).....	18
Şekil 2.9: Geleneksel ve derin sinir ağları ( <i>Introducing Deep Learning with MATLAB, 2020</i> ).....	20
Şekil 2.10 Tekrarlayan sinir ağı (RNN) yapısı ( <i>Recurrent Neural Networks (RNN) Tutorial Using TensorFlow In Python - Edureka, 2019</i> ) .....	21
Şekil 2.11 LSTM hücresi yapısı ( <i>Introduction to LSTM Units in RNN   Pluralsight, 2020</i> ).....	23
Şekil 2.12 LSTM ağı unutmama kapısı işlem süreci.....	24
Şekil 2.13 LSTM ağı giriş kapısı işlem süreci .....	24
Şekil 2.14 LSTM ağı hücre durumu işlem süreci.....	25
Şekil 2.15: LSTM ağı çıktı kapısı işlem süreci .....	26
Şekil 2.16: Çift yönlü uzun kısa süreli bellek ağı yapısı (Murad ve Pyun, 2017).....	27
Şekil 3.1: İnşaat çalışma alanı ve veri toplama araçları .....	28

Şekil 3.2 Hareket veri toplanmasında kullanılan sensörlere ait görüntüler ( <i>Wearnotch / Wearable 3D motion capture / Free apps / Mobile SDK / Template Code</i> , 2017) .....	29
Şekil 3.3: Sensörleden elde edilen verilere ilişkin örnek ekran görüntüsü.....	30
Şekil 3.4: Ses verileri toplanmasında kullanılan Sensorlog yazılımına ait ekran görüntüleri ( <i>SensorLog</i> , 2021).....	31
Şekil 3.5: IOS yerleşik sesli not yazılımı ile kaydedilen duvar işine ait ses verileri ekran görüntüsü .....	32
Şekil 3.6: Veri toplama öncesi sensör takılmış inşaat ustaları .....	34
Şekil 3.7: İnşaat işçilerine sensör takılan 11 adet nokta görüntüsü.....	35
Şekil 4.1: Tez kapsamında oluşturulan derin öğrenme ağı şematik görüntüsü .....	47
Şekil 4.2: Hiperparametre Set1 için hata matrisi görüntüsü.....	50
Şekil 4.3: Hiperparametre Set2 için hata matrisi görüntüsü.....	51
Şekil 4.4: Hiperparametre Set3 için hata matrisi görüntüsü.....	52
Şekil 4.5: Hiperparametre Set4 için hata matrisi görüntüsü.....	53
Şekil 4.6: Hiperparametre Set5 için hata matrisi görüntüsü.....	54
Şekil 4.7: Hiperparametre Set6 için hata matrisi görüntüsü.....	55
Şekil 4.8: Her bir parametre setine ait eğitim doğruluk oranı grafiği.....	56
Şekil 4.9: İvme sensör verileri derin öğrenme ağı nihai eğitim ekran görüntüsü.....	57
Şekil 4.10: İvme sensörü verileri nihai eğitim hata matrisi ekran görüntüsü .....	58
Şekil 4.11: Test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik .....	59
Şekil 4.12 Yeni test verileri ile yapılan eğitim çalışması hata matrisi .....	61
Şekil 4.13: Yeni test verileri ve tahminleri zaman-aktivite bazında gösterir grafik.....	62
Şekil 4.14: Hiperparametre Set1 için hata matrisi görüntüsü.....	64
Şekil 4.15: Hiperparametre Set2 için hata matrisi görüntüsü.....	65
Şekil 4.16: Hiperparametre Set3 için hata matrisi görüntüsü.....	66
Şekil 4.17: Hiperparametre Set4 için hata matrisi görüntüsü.....	67
Şekil 4.18: Hiperparametre Set5 için hata matrisi görüntüsü.....	68
Şekil 4.19: Hiperparametre Set6 için hata matrisi görüntüsü.....	69



Şekil 4.20: Her bir parametre setine ait eğitim doğruluk oranı grafiği.....	70
Şekil 4.21: Sensör konum verileri derin öğrenme ağı nihai eğitim süreci ekran görüntüsü .....	71
Şekil 4.22: Sensör konum verileri nihai eğitim hata matrisi ekran görüntüsü .....	72
Şekil 4.23: Test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik .....	73
Şekil 4.24: Yeni test verileri ile yapılan eğitim çalışması hata matrisi .....	75
Şekil 4.25: Yeni test verileri ve tahminleri zaman-aktivite bazında gösterir grafik.....	76
Şekil 4.26: Hiperparametre Set1 için hata matrisi görüntüsü.....	78
Şekil 4.27: Hiperparametre Set2 için hata matrisi görüntüsü.....	79
Şekil 4.28: Hiperparametre Set3 için hata matrisi görüntüsü.....	80
Şekil 4.29: Hiperparametre Set4 için hata matrisi görüntüsü.....	81
Şekil 4.30: Hiperparametre Set5 için hata matrisi görüntüsü.....	82
Şekil 4.31: Hiperparametre Set6 için hata matrisi görüntüsü.....	83
Şekil 4.32: Her bir parametre setine ait eğitim doğruluk oranı grafiği.....	84
Şekil 4.33: Sensör konum ve ivme verileri derin öğrenme ağı nihai eğitim süreci ekran görüntüsü .....	85
Şekil 4.34: Sensör konum verileri nihai eğitim hata matrisi ekran görüntüsü .....	86
Şekil 4.35: Test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik .....	87
Şekil 4.36: Yeni test verileri ile yapılan eğitim çalışması hata matrisi .....	89
Şekil 4.37: Yeni test verileri ve tahminleri zaman-aktivite bazında gösterir grafik.....	90
Şekil 4.38: Hiperparametre Set1 için hata matrisi görüntüsü.....	92
Şekil 4.39: Hiperparametre Set2 için hata matrisi görüntüsü.....	93
Şekil 4.40: Hiperparametre Set3 için hata matrisi görüntüsü.....	94
Şekil 4.41: Hiperparametre Set4 için hata matrisi görüntüsü.....	95
Şekil 4.42: Hiperparametre Set5 için hata matrisi görüntüsü.....	96
Şekil 4.43: Hiperparametre Set6 için hata matrisi görüntüsü.....	97
Şekil 4.44: Eğitim hiperparametre setleri sonuç özeti.....	98

Şekil 4.45: Sensorlog ses verileri derin öğrenme ağı nihai eğitim süreci ekran görüntüsü .....	99
Şekil 4.46: Sensör konum verileri nihai eğitim hata matrisi ekran görüntüsü .....	100
Şekil 4.47: Test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik .....	101
Şekil 4.48: İşçinin hangi işi ne kadar süre ile yaptığını gösterir program çıktısı .....	102
Şekil 4.49: Hiperparametre Set1 için hata matrisi görüntüsü .....	104
Şekil 4.50: Hiperparametre Set2 için hata matrisi görüntüsü .....	105
Şekil 4.51: Hiperparametre Set3 için hata matrisi görüntüsü .....	106
Şekil 4.52: Hiperparametre Set1 için hata matrisi görüntüsü .....	107
Şekil 4.53: Hiperparametre Set5 için hata matrisi görüntüsü .....	108
Şekil 4.54: Hiperparametre Set5 için hata matrisi görüntüsü .....	109
Şekil 4.55: Her bir parametre setine ait eğitim doğruluk oranı grafiği .....	110
Şekil 4.56: Ses verileri derin öğrenme ağı nihai eğitim ekran görüntüsü .....	111
Şekil 4.57: Ses verileri nihai eğitim hata matrisi ekran görüntüsü .....	112
Şekil 4.58: Test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik .....	113
Şekil 5.1: Aynı parametre seti ile farklı sensör verileri hata matrisleri .....	117
Şekil 5.2: Aynı parametre seti ile test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik .....	117

## TABLO LİSTESİ

### Sayfa No

Tablo 2.1 : İnsan hareketi tanımlamada yoğun olarak kullanılan veri setlerinin özellikleri (Chen ve diğ., 2018; Wang ve diğ., 2019).....	7
Tablo 2.2: Tez çalışması kapsamında incelenen insan hareketi tanımlama araştırmalarına ilişkin özet tablo (Wang ve diğ., 2019).....	10
Tablo 3.1: Sensör ve ses verilerine ait toplam kayıt veri özeti.....	33
Tablo 3.2: İş bazında sensör verilerine ait kayıtların detaylı özeti.....	35
Tablo 3.3: Sersorlog programı ses verilerinin iş bazında özeti .....	37
Tablo 3.4: IOS sesli not programı ile kaydedilen verilerin iş bazında özeti .....	38
Tablo 3.5: Sensör test verileri iş bazında özet bilgileri .....	42
Tablo 3.6: Ses test verilerinin iş bazında özet bilgileri.....	44
Tablo 4.1: Sensör verileri için kullanılan hiperparametre setlerine ait değerler .....	49
Tablo 4.2: Eğitim parametre setleri sonuç özeti.....	56
Tablo 4.3: Toplam test verisi ve tahmin değerleri çıktısı .....	58
Tablo 4.4: İş bazında test verileri tahmin oranlarını gösterir tablo .....	59
Tablo 4.5: İş bazında tahminlerin yüzdesel dağılım özeti.....	60
Tablo 4.6: İşçinin hangi işi ne kadar süre ile yaptığını gösterir program çıktısı .....	60
Tablo 4.7: Toplam yeni test verisi ve tahmin değerleri çıktısı .....	62
Tablo 4.8: Sensör verileri için kullanılan hiperparametre setlerine ait değerler .....	63
Tablo 4.9: Eğitim hiperparametre setleri sonuç özeti.....	70
Tablo 4.10: Toplam test verisi ve tahmin değerleri çıktısı .....	72
Tablo 4.11: İş bazında test verileri tahmin oranlarını gösterir tablo .....	73
Tablo 4.12: İş bazında tahminlerin yüzdesel dağılım özeti.....	74
Tablo 4.13: İşçinin hangi işi ne kadar süre ile yaptığını gösterir program çıktısı .....	74
Tablo 4.14: Toplam yeni test verisi ve tahmin değerleri çıktısı .....	76

Tablo 4.15: Sensör ve konum verileri için kullanılan hiperparametre setlerine ait değerler.....	77
Tablo 4.16: Eğitim hiperparametre setleri sonuç özeti.....	84
Tablo 4.17: Toplam test verisi ve tahmin değerleri çıktısı.....	86
Tablo 4.18: İş bazında test verileri tahmin oranlarını gösterir tablo.....	87
Tablo 4.19: İş bazında tahminlerin yüzdesel dağılım özeti.....	88
Tablo 4.20: İşçinin hangi işi ne kadar süre ile yaptığını gösterir program çıktısı.....	88
Tablo 4.21: Toplam yeni test verisi ve tahmin değerleri çıktısı.....	90
Tablo 4.22: Ses verileri için kullanılan hiperparametre setlerine ait değerler.....	91
Tablo 4.23: Eğitim hiperparametre setleri sonuç özeti.....	98
Tablo 4.24: Toplam test verisi ve tahmin değerleri çıktısı.....	100
Tablo 4.25: İş bazında test verileri tahmin oranlarını gösterir tablo.....	101
Tablo 4.26: İş bazında tahminlerin yüzdesel dağılım özeti.....	102
Tablo 4.27: Sensör verileri için kullanılan hiperparametre setlerine ait değerler.....	103
Tablo 4.28: Eğitim parametre setleri sonuç özeti.....	110
Tablo 4.29: Toplam test verisi ve tahmin değerleri çıktısı.....	112
Tablo 4.30: İş bazında test verileri tahmin oranlarını gösterir tablo.....	113
Tablo 4.31: İş bazında tahminlerin yüzdesel dağılım özeti.....	114
Tablo 4.32: İşçinin hangi işi ne kadar süre ile yaptığını gösterir program çıktısı.....	114
Tablo 5.1: Sensör çalışmalarının karşılaştırmalı sonuçları.....	116
Tablo 5.2: Aynı eğitim parametleri ile tek LSTM katmanlı sensör çalışma sonuçları karşılaştırma.....	116

## SİMGE VE KISALTMA LİSTESİ

<b>Simgeler</b>	<b>Açıklama</b>
<b>C</b>	: Hücre Durumu
<b>f</b>	: Unutma Kapısı
<b>h</b>	: Gizli Durum
<b>O</b>	: Çıkış Kapısı
<b><math>\sigma</math></b>	: Sigmoid Fonksiyon
<b>tanh</b>	: Hiperbolik Tanjant Fonksiyonu

<b>Kısaltmalar</b>	<b>Açıklama</b>
<b>ANN</b>	: Artificial Neural Network
<b>BiLSTM</b>	: Bidirectional Long Short-Term Memory
<b>CNN</b>	: Convolutional Neural Network
<b>HAR</b>	: Human Activity Recognition
<b>IMU</b>	: Inertial Measurement Unit
<b>İHT</b>	: İnsan Hareketi Tanımlama
<b>KNN</b>	: K-Nearest Neighbour
<b>LSTM</b>	: Long Short-Term Memory
<b>RNN</b>	: Recurrent Neural Network
<b>SVM</b>	: Support Vector Machine

## ÖZET

### DOKTORA TEZİ

#### İNŞAAT SÜRECİNDE İŞÇİ AKTİVİTELERİNİN DERİN ÖĞRENME İLE OTOMATİK SINIFLANDIRILMASI

Ömür TEZCAN

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

İnşaat Mühendisliği Anabilim Dalı

Danışman : Dr. Öğr. Üyesi Cemil AKÇAY

Diğer sektörlerde artan robotik üretime karşın inşaat projeleri hala en yoğun insan iş gücü kaynağının kullanıldığı sektörler arasında yer almaktadır. İnşaat yapım sürecinde işçi aktivitelerinin yüksek doğrulukla otomatik tespiti, projelerde zaman ve maliyet yönetimi açısından oldukça önemlidir. Tez çalışmasında işçi aktivitelerinin derin öğrenme tabanlı otomatik tespiti ve takibi ile verimlilik ve performans kaybının önlenmesine yönelik stratejilerde karar desteği sağlaması hedeflenmiştir. Bu amaçla inşaat işçilerinin vücutlarına yerleştirilen sensörlerden elde edilen veriler ve ortam ses kaydı verileri ile iş aktivitesi tespiti yapılmıştır. Çalışmada sensör ivme verileri yanında sensör konum verileri ve bu ikisinin kombinasyonunda kullanılarak sonuçlar değerlendirilmiştir. Aktivite tanımlama için derin öğrenme LSTM ve BiLSTM ağları birlikte kullanılmıştır. Çalışma sonucunda üç adet sensör verilerinden ve iki adet ses verilerinden olmak üzere toplam beş farklı çalışmada %97-%100 arasında doğruluk oranı yakalanmıştır. Bu oranlarla, işçi aktivitelerinin otomatik tespitinin inşaat projelerinde iş verimliliği kaynaklı süre ve maddi kayıpların önlenmesinde önemli bir karar desteği sağlayacağı değerlendirilmektedir.

Mart 2021, 145 sayfa.

**Anahtar kelimeler:** İnsan Hareketi Tanımlama, Derin Öğrenme, LSTM, Vücut Hareket Sensörleri, Ses Sınıflandırma

## **SUMMARY**

### **Ph.D. THESIS**

#### **AUTOMATIC CLASSIFICATION OF WORKER ACTIVITIES WITH DEEP LEARNING IN CONSTRUCTION PROCESS**

**Ömür TEZCAN**

**Istanbul University-Cerrahpasa**

**Institute of Graduate Studies**

**Department of Civil Engineering**

**Supervisor : Assist. Prof. Dr. Cemil AKÇAY**

Despite the increasing robotic production in other sectors, construction projects are still among the sectors where the most human labor resource is used. Automatic detection of worker activities with high accuracy during the construction process is very important in terms of time and cost management in projects. In the thesis, it was aimed to provide decision support in strategies for preventing loss of productivity and performance with automatic detection of worker activities based on deep learning. For this purpose, work activity was determined with the data obtained from the sensors placed on the construction workers' bodies and the ambient sound recording. In the study, the results were evaluated by using the sensor position data and the combination of these two as well as the sensor acceleration data. Deep learning LSTM and BiLSTM networks were used together for activity identification. As a result of the study, accuracy rate between 97% and 100% was achieved in five different studies, including three sensor data and two audio data. It is considered that automatic determination of worker activities with these high rates, will provide an important decision support in preventing time and financial losses due to work efficiency in construction projects.

March 2021, 145 pages.

**Keywords:** Human Activity Recognition (HAR), Deep Learning, LSTM, Body Motion Sensors, Sound Classification

## 1. GİRİŞ

Son yıllarda dijitalleşme ve teknolojik gelişmelere bağlı olarak her iş alanında önemli değişimler yaşanmaktadır. Yapay zeka, makine öğrenmesi, nesnelerin interneti, derin öğrenme ve 3D baskı gibi teknolojik gelişmeler her sektörü hızlı biçimde değiştirmektedir. Bu kapsamda inşaat sektöründeki durum incelendiğinde, inşaat sektörünün değişim ve yenilikte finans, telekom, havacılık, otomotiv gibi sektörlerin çok gerisinde olduğu gözlenmiştir. Bu tür yenilik ve gelişmelerin temelini oluşturan araştırma ve geliştirme faaliyetleri için ayrılan bütçe otomotiv ve havacılık sektörlerinde toplam gelirin % 3,5 – 4,5 aralığında iken inşaat sektöründe bu oran % 1' in altında olduğu görülmektedir (Tezcan ve diğ., 2019).

Bu çalışma kapsamında öncelikle inşaat sektöründeki araştırmaların ne yönde geliştiğini görmek amacıyla “Automation in Construction” ve “Advance Engineering Enformatics” dergilerindeki son 2012-2018 yılları arasındaki yayınlar incelenmiştir. Bu incelemede özellikle son üç yılda toplam sayı artış oranı olarak sırasıyla derin öğrenme, 3D baskı, nesnelerin interneti ve makine öğrenmesinin ilk dört sırayı aldığı görülmüştür. İnşaat sektöründe makine öğrenmesi ve derin öğrenme ile ilgili çalışmaların ağırlıklı olarak kamera görüntüleri ile iş güvenliği risklerinin belirlenmesi ve kalite hatalarının tespiti üzerine yoğunlaştığı görülmüştür.

Özellikle tüm sektörlerde süreçlerin otomasyonu ile ilgili çalışmalar artarak devam etmektedir. İnşaat sektöründe her projenin kendine has dinamikleri olması nedeniyle inşaat yapım sürecinde otomasyon uygulamasının zorluklarına karşın proje yönetim süreçlerinde otomasyon ile ilgili çalışmalar yürütülmektedir. Bununla birlikte her projenin farklı olmasından dolayı, sanayi sektöründe olduğu gibi inşaat sektöründe üretim yöntemleri standardize edilememektedir. Diğer sektörlerdeki yoğun robotik üretime karşın inşaat sektörü hala en yoğun insan iş gücünün kullanıldığı sektörler arasında yer almaktadır.

Bu noktadan hareketle inşaat yapım sürecinde işçi aktivitelerinin otomatik tespiti proje performansı açısından büyük önem taşımaktadır. Bu otomatik tespit işçi verimliliğinin değerlendirilmesi, iş süreç optimizasyonu, iş performansının değerlendirilmesi, iş süresinin tespiti gibi birçok tespite baz ilk adımı oluşturmaktadır. Çok yoğun iş gücü kullanılan inşaat projelerinde işçi aktivitelerinin yüksek doğrulukla otomatik tespitinin hem süre hem maliyete dolaylı etkisi tez çalışmasının temel motivasyon kaynağını oluşturmaktadır.



Tez çalışmasındaki işçi aktivitelerinin derin öğrenme ile otomatik tespiti sayesinde, verimlilik ve performans kaybının önlenmesine yönelik stratejilerde karar desteği sağlaması hedeflenmiştir. Bu sayede iş verimliği kaynaklı süre ve maddi kayıplar önemli oranda azaltılmış olacaktır.

Bu amaçla öncelikle insan aktivite tespiti ile ilgili veri toplama ve sonrasında kullanılan yöntemlere literatür taraması yapılmıştır. Literatür taramasında genel insan aktivitesi tespit çalışmaları ve inşaat sektöründe yapılan işçi aktivite tespit çalışmaları üzerinde yoğunlaşmıştır. Bölüm 2’de yer verilen bu çalışmalarda ağırlıklı olarak veri toplama yöntemleri, hazır veri seti olup olmadığı, toplanan veya hazır veri setinin büyüklüğü, veri setinin içeriği, verilerin eğitim öncesi nasıl işlendiği, kullanılan yöntemler ve sonuçları incelenmiştir.

Literatür taraması sonucu makine öğrenmesi veya derin öğrenme ile ilgili yapılan çalışmalarda ağırlıklı hazır veri setlerinin kullanıldığı, sağlık alanında yapılan çalışmalarda ağırlıklı kendi verilerinin kullanıldığı, inşaat sektöründe konuya ilişkin yapılan kısıtlı çalışmalarda ise ağırlıklı makine öğrenmesi yöntemlerinin kullanıldığı görülmüştür. İnşaat sektöründe sensör tabanlı işçi aktivitesi tanımlama çalışmaları yer almakla birlikte, ses tabanlı aktivite tanımlama çalışmalarınının iş makine aktivitesi tanımlama üzerinde yoğunlaştığı, ses tabanlı işçi aktivitesi tanımlama çalışmasına ise rastlanılmamıştır.

Bu noktadan hareketle tez çalışması; yapılan iş aktivitesi serisinde birim frekans zamanında tahmini ve kullanılan LSTM yöntemi ile inşaat sektöründeki yapılan diğer çalışmalardan ayrılmaktadır. Bununla birlikte tüm vücut sensör verisi toplama, 6 ayrı iş aktivitesini %97-%100 doğruluk ile tespit, sensörlerden elde edilen vücut konum verilerinin kullanılması, sensör verilerinde ivme ve vücut konum verilerinin birlikte kullanılması, aynı aktivitelerin ortamdaki iki farklı ses kayıt yöntemi ile tahminlenmesi bu tez çalışması kapsamında taranan diğer çalışmalardan farklı yönler olarak öne çıkmaktadır.

Tez çalışması başlangıcında iki adet usta ile sıva ve boya işi için sağ ve sol el ivme sensörü verileri kullanılmıştır. Bu veriler ile derin öğrenme LSTM ağı kullanılarak geliştirilen algoritma ile çalışma yapılmıştır. Çalışma başında % 86 civarında olan doğruluk oranı yakalanmışken, hiperparametre optimizasyonu ve BiLSTM katmanı ile derinlik artırılarak %97-%100 doğruluk oranı yakalanmıştır. Sonrasında farklı işçi ve iş aktivitelerindeki başarı oranını görmek üzere 2

olan işçi sayısı 5'e çıkarılmıştır. Bununla birlikte sadece sıva ve boya aktivitesine ilave olarak tuğla duvar, laminat parke, seramik döşeme, kalıp işide eklenerek aktivite sayısı 6 adete çıkarılmıştır. Bu süreçte yine sağ ve sol el sensörlere vücudun 11 noktasından veriler eklenmiştir. Ayrıca vücuda bağlı sensörler yanında ortam sesinden iş tahmini için çalışma ortamında iki noktadan iki farklı yöntemle ses verileri toplanmıştır. Böylece tez çalışması kapsamında sensörler ve ses toplam 215.780.548 adet veri toplanmıştır. Veri toplama ve ön işleme süreci Bölüm 3'te detaylı olarak anlatılmıştır.

Çalışma başlangıcında sensör verilerinden sadece ivme sensörü verileri kullanılmıştır. Sonrasında çalışma sırasında kullanılan sensörlerden elde edilen ilgili sensörün konum verilerinin doğruluğa katkısını araştırmak için çalışmaya konum verileri de eklenmiştir. Ayrıca yine bu iki verinin birlikte etkisini görmek amacıyla bu iki verinin birlikte kullanıldığı bir çalışma yapılmıştır. Böylelikle tez kapsamında sensör verilerinden 3 farklı çalışma gerçekleştirilmiştir.

Ses verileri toplanması aşamasında, işin yapımı sırasında sabit iki noktadan cep telefonu mikrofonu ile ses verileri kaydedilmiştir. Bir tanesinde mikrofon ile normal ses kaydı diğerinde ise Sensorlog yazılımı ile sesin dB cinsinden şiddeti ve ortalaması kayıt altına alınmıştır. Her iki farklı veri seti ile yapılan eğitim sonucu % 97-100 doğruluk oranı yakalanmıştır.

Ayrıca yine tez sürecinde derin öğrenme LSTM yöntemi hiperparametrelerinin eğitime etkisini görmek amacıyla 6 farklı parametre setinin aynı anda eğitildiği bir algoritma kullanılmış böylelikle hem sensör hem ses verileri önce farklı parametreler ile eğitilmiş sonrasında en iyi parametre setine yakın parametrelerle nihai eğitim gerçekleştirilmiştir. Hem sensör hem ses verileri için eğitim parametre değişimlerinin etkisi ve nihai eğitim sonuçları Bölüm 4'te sunulmuştur.

Sensör ve ses verilerinden oluşan beş ayrı çalışmayı içeren bu tez çalışmasının sonuçları ve değerlendirme Bölüm 5'te sunulmuştur. Ayrıca sonuç bölümünde sensör ivme verileri yanında sensör konum verileri ve bu ikisinin birlikte kullanımı ile yapılan çalışmaların aynı parametre setleri ile etkilerini görmek amacıyla bir çalışma daha eklenerek sonuçları sunulmuştur. Tez çalışması zaman serisi tahmini, farklı sensör verileri kombinasyonu, ortam ses verileri, LSTM ve BiLSTM derin öğrenme ağı, hiperparametre optimizasyonuna yönelik eş zamanlı eğitim algoritması içermesi ile literatürdeki mevcut çalışmalara katkı sunması beklenmektedir. Ayrıca

iŒi aktivitelerinin %97 - %100 arasında dođrulukla otomatik olarak tahmini ile verimlilik, performans ynetimi, proje ilerleme kontrol gibi hususlarda destek sađlayacađı deđerlendirilmektedir.



## 2. GENEL KISIMLAR


### 2.1. İNSAN HAREKETLERİ TANIMLAMA VE YAPILAN ÇALIŞMALAR:

İnsan Hareketleri Tanımlama (İHT) yabancı literatürde “Human Activity Recognition (HAR)” olarak geçmekte ve bilgisayar bilimi kullanılarak, kullanıcıların gereksinimlerine göre otomatik insan davranışlarını anlamayı amaçlayan sistemler olarak tanımlanmaktadır. (Bulling ve diğ., 2014).

Son dönemde özellikle yapay zeka alanındaki ve bilgisayar sistemlerindeki gelişmeler ile İHT ile ilgili çalışmaların arttığı gözükmektedir. Yapılan literatür taramalarında çalışmaların özellikle 2015 yılı sonrası ciddi ivme kazandığı görülmektedir.

İnsan aktivite tanımlama için yapılan çalışmalarda sensör, kamera görüntüleri ve çok sınırlı olsa ses tabanlı yöntemlerin kullanıldığı görülmüştür. Cook ve diğ. (2013) ile Hussain ve diğ. (2019) İHT'nin video tabanlı ve sensör tabanlı iki ana tipi vardır derken, Sherafat ve diğ.(2020) kinematik tabanlı, görüntü tabanlı ve ses tabanlı olmak üzere üç ana tipi ayırmıştır. Tez çalışması kapsamında görüntü haricinde sensör ve ses tabanlı olmak üzere iki yöntem kullanılmıştır.

Temel olarak her üç yöntemde üç ana temel adımdan oluşmaktadır. İlk adımda veri toplama süreci, sonrasında makine öğrenmesi ise özellik çıkarımı ve eğitim, derin öğrenme ise derin öğrenme ağı ve eğitim son adım ise aktivite tahmini sonuç çıktısı ve değerlendirmedir.



Şekil 2.1: İnsan hareketi tanımlama süreci

Yapılan literatür taramasında görüntü ve ses tabanlı çalışmalarda arařtırmacılar kendi verilerini kullanırken, kinematik veya sensör tabanlı çalışmalarda ağırlıklı olarak hazır veri setleri kullanıldığı görülmüştür. Görüntü ve ses verilerini toplamak daha kolay bir yöntem iken Sherafat ve diğ.(2020) kinematik tabanlı uygulamaların doğruluk oranı ve bilgi işleme hızını diğeri iki yönetime göre daha etkili olarak tanımlamaktadırlar. Bunda en önemli etken olarak ses ve görüntü verilerinin hava durumu, toz, çevre gürültü vs. gibi çevresel etkilerden çok etkilendiği veri kirlenmiş verinin doğruluk oranını düşürdüğünü belirtmişlerdir. Görüntü işleme için diğeri bir sorun ise yüklü miktarda veri içermesi nedeniyle hem bunların depolanması hemde işlenmesi için ciddi sistem gereksinimine ihtiyaç duyması olarak gösterilmiştir. Görüntü işleme süreci sensör ve ses verilerine göre oldukça uzun sürmektedir.

Literatürde incelenen çalışmalarda ağırlıklı olarak kullanılan hazır veri setlerinden 4 tanesi ön plana çıkmaktadır. Bunlar UCI Smartphone, Opportunity, Skoda Checkpoint ve Pamap2 veri setleridir. Skoda Checkpoint veri seti bir araç kontrol noktasındaki hareketleri içermekte iken diğeri tüm veri setleri günlük hareketleri içermektedir. En çok kullanılan UCI Smartphone veri seti, katılımcıların bel çevresine takılan bir akıllı telefonun yerleşik ivmeölçer sensöründen ve 22-79 yaş grubundaki 30 katılımcıdan toplanmıştır. Her aktivite (ayakta durma, oturma, uzanma, yürüme, merdiven tırmanma, merdivenden inme) 60 saniye boyunca gerçekleştirilmiş ve 3 eksenli doğrusal hızlanma ve 3 eksenli açısal hız sabit 50Hz frekansta toplanmıştır. Diğeri bir veri seti olan Pamap2'de 1 kadın 8 erkek katılımcının el bileği, ayak bileği ve göğüste yer alan üç adet IMU sensör ile 100 Hz frekansta kayıt gerçekleştirilmiştir. Bu veri setinde de koşma, yürüme, uzanma, ütü yapma, ip atlama, bisiklete binme gibi günlük aktiviteler kaydedilmiştir. Skoda Checkpoint veri setinde ise araba bakım istasyonunda kapı açma, kapı kapama, not alma, lastikleri kontrol etme gibi 10 adet aktivite her bir kolda 10 adet olmak üzere iki koldaki toplam 20 sensör ile 98 Hz frekansta kaydedilmiştir. UCI Smartphone ve Skoda veri setleri kayıt görüntüleri aşağıda sunulmuştur.



Şekil 2.2: UCI Smartphone ve Skoda Checkpoint setleri veri toplama görüntüleri (*wiki:dataset [Human Activity/Context Recognition Datasets], 2020; UCI Machine Learning Repository: Smartphone Dataset for Human Activity Recognition (HAR) in Ambient Assisted Living (AAL) Data Set, 2020*)

Wang ve diğ. (2019) ile Chen ve diğ. (2018) yaptıkları araştırmada bu veri setleri ile ilgili özet çalışma hazırlamışlardır. Bu çalışmadan oluşturulmuş 15 adet hazır veri setine ait özet veri tablosu aşağıda sunulmuştur.

Tablo 2.1 : İnsan hareketi tanımlamada yoğun olarak kullanılan veri setlerinin özellikleri (Chen ve diğ., 2018; Wang ve diğ., 2019)

Veri Seti	Aktivite Türü	Denek Sayısı	Kayıt Frekans	Aktivite Sayısı	Sensörler
UCI Smartphone	Günlük	30	50 Hz	6	İvme, Jireskop
Skoda Checkpoint	Araç Bakım	1	96 Hz	10	İvme, Jireskop
Pamap 2	Günlük	9	100 Hz	18	İvme, Jireskop, Magnometre
Opportunity	Günlük	4	32 Hz	16	İvme, Jireskop, Magnometre
USC-HAD	Günlük	14	100 Hz	12	İvme, Jireskop
WISDM	Günlük	29	20 Hz	6	İvme
DSADS	Günlük	8	25 Hz	19	İvme, Jireskop, Magnometre
Darmstadt Daily Routines	Günlük	1	100 Hz	35	İvme
Actitracker	Günlük	36	20 Hz	6	İvme
SHO	Günlük	10	50 Hz	7	İvme, Jireskop, Magnometre
MHEALTH	Günlük	10	50 Hz	12	İvme, Jireskop, Magnometre
Daphnet Gait	Günlük	10	64 Hz	2	İvme


Veri Seti	Aktivite Türü	Denek Sayısı	Kayıt Frekans	Aktivite Sayısı	Sensörler
ActiveMiles	Günlük	10	50 Hz	7	İvme
HASC	Günlük	1	200 Hz	13	İvme
Heterogeneous	Günlük	9	100 Hz	6	İvme, Jireskop

Hazır veri setleri incelendiğinde denek sayısı ve aktivite sayısı medyanı 10, frekans medyanı 50 olarak hesaplanmıştır. Literatürde kullanılan en çok kullanılan hazır veri seti olan UCI seti tez çalışmasında toplanan veri seti ile karşılaştırıldığında her ikisinin kaydında da 50 Hz frekans kullanıldığı ve 6 aktiviteden oluştuğu görülmektedir. Farklı olarak UCI veri setinde sadece belde yer alan akıllı telefon sensöründen veri alınırken, bu tez çalışmasında kollar, bacaklar, bel, göğüs ve baş olmak üzere 11 ayrı noktadaki sensörden veri toplanmıştır.

### 2.1.1. Sensör Tiplerine Göre İnsan Hareketi Tanımlama

Sensör tiplerine göre İHT Chavarriaga ve diğ. (2013) üç ayrı gruba ayrılmıştır. Bunlar vücut yerleşimli, nesne yerleşimli ve ortam yerleşimli olarak tanımlanmıştır. Wang ve diğ (2019) bunlara ilave olarak herhangi ikisinin beraber kullanıldığı karma kullanımı eklemiştir. Tez çalışmasında vücut üzerine yerleşimli sensörler kullanılmıştır. Bununla birlikte ilave olarak ses kaydı ile ortam sensöründe kullanılmıştır. Aynı iş tanımlarımı için hem sensör hem ses ile çalışma yapılmasına karşın bunlar tahminde kombine kullanılmadığı için karma kullanım olarak tanımlanamamaktadır.

Vücuda takılan sensörler, insan hareketi tanıma çalışmalarında en yaygın kullanılan yöntemlerden biridir. Bu sensörler genellikle ivmeölçer, manyetometre ve jiroskop gibi sensörlerden oluşmakta olup bu sensörlerin birlikte yer aldığı IMU sensörlerde kullanılmaktadır. Sensörlerden tarafından kaydedilen ivme ve açısal hız insan hareketlerine göre değişmektedir. Örnek olarak çalışma sırasında kaydedilen ivmeölçer verilerine ilişkin grafik aşağıda sunulmuştur. Grafikte sunulan X,Y,Z ekseninde yer alan verilerden ilk 5500 adeti 3 adet boya işine ait olup kalan kısmı ise 3 adet sıva işine aittir.



Şekil 2.3: Sıva ve boya işine ait sensör verilerinin x,y,z eksenindeki görüntüleri

### 2.1.2. Sensör Kullanılarak Yapılan İnsan Hareketi Tanımlama Çalışmaları

Vücuda takılan sensör uygulamalarında hem makine öğrenmesi hemde derin öğrenme tabanlı İHT yaygın olarak kullanılmıştır. Sensörler arasında ivmeölçer çoğunlukla olmak üzere Jiroskop ve manyetometre de sıklıkla ivmeölçer ile birlikte kullanılmıştır. Çalışmalar incelendiğinde sensörler genellikle günlük yaşam hareketleri tanımak için kullanıldığı görülmüştür. Bunda en önemli nedeni İHT hazır veri setlerinde ağırlıklı günlük aktivitelerin kullanılması olarak değerlendirilmiştir.

Aşağıda literatür araması kapsamında sensörler ve derin öğrenme kullanılarak yapılan İHT çalışmalarındaki sensör kullanım şekilleri, tahminlenen hareket, kullanılan veri seti ve çalışma ile ulaşılan doğruluk oranı paylaşılmıştır.

Derin öğrenme ile yapılmış aşağıda incelenen çalışmalarda; insan hareketi tahmin doğruluk oranlarının %72 ve %99 arasında değiştiği gözükmektedir. Tüm çalışmalarda başarı ortalaması % 92,87 iken medyan % 94,43 olarak hesaplanmıştır.

Sadece hazır veri seti kullanılan çalışmalarda doğruluk oranı ortalaması % 94,64 iken kendi veri setini kullanan çalışmalarda doğruluk oranı ortalamasının %91,09 olduğu görülmektedir.



Tablo 2.2: Tez çalışması kapsamında incelenen insan hareketi tanımlama arařtırmalarına iliřkin özet tablo (Wang ve dię., 2019)

Arařtırma / Makale	Sensör Kullanım Şekli	Arařtırma Uygulaması	Veri Seti	Başarı Oranı
Wan, S. ve dię. (2020)	Vücut Yerleřim Sensör	Günlük Aktivite	UCI Smartphone, Pamap2	93%
Inoue ve dię. (2018)	Vücut Yerleřim Sensör	Günlük Aktivite	UCI Smartphone, HASC	95%
Almaslukh ve dię. (2017)	Vücut Yerleřim Sensör	Günlük Aktivite	UCI Smartphone	98%
Cheng ve dię. (2017)	Vücut Yerleřim Telefon Sensör	Parkinson Hastaları Yürüyüş ve Günlük Aktivite	Kendi Veri Seti	98%
Guan ve Ploetz (2017)	Vücut Yerleřim, Nesne, Ortam Sensör	Günlük Aktivite	Opportunity, Skoda, Pamap2	92%
Hannink ve dię. (2017)	Vücut Yerleřim Sensör	Yürüyüş Bozukluęu Analizi	Kendi Veri Seti	95%
Khan ve dię. (2017)	Ortam Sensörü	Nefes Alma Oranı	Kendi Veri Seti	95%
Kim ve Li (2017)	Vücut Yerleřim Sensör	Günlük Aktivite	Kendi Veri Seti	99%
Lee ve dię. (2017)	Vücut Yerleřim Sensör	Günlük Aktivite	Kendi Veri Seti	93%
Murad ve Pyun. (2017)	Vücut Yerleřim Sensör	Günlük Aktivite	Opportunity, Skoda, USC-HAD, Daphnet Gait	97%
Ravi ve dię. (2017)	Vücut Yerleřim Sensör	Günlük Aktivite	Skoda, WISDM, Daphnet Gait, Active Miles	99%
Yao ve dię. (2017)	Vücut Yerleřim Sensör, Nesne Yerleřimli Sensör	Günlük Aktivite	Kendi Veri Seti, Heterogeneous	94%
Zhang, Y. ve dię. (2017)	Nesne Yerleřimli Sensör (RFID)	Yoęun Bakım Medikal Aktivite	Kendi Veri Seti (RFID)	84%
Zhang, S. ve dię. (2017)	Vücut Yerleřim Sensör	Günlük Aktivite	Kendi Veri Seti	99%
Alsheikh ve dię. (2016)	Vücut Yerleřim Sensör	Günlük Aktivite, Parkinson Yürüyüş Donma Tespit	Skoda, WISDM, Daphnet Gait	89,38% 98,23%

Araştırma / Makale	Sensör Kullanım Şekli	Araştırma Uygulaması	Veri Seti	Başarı Oranı
Bhattacharya ve Lane (2016)	Vücut Yerleşim, Ortam Sensörü	Günlük Aktivite	Kendi Veri Seti, Opportunity	72%
Chen ve diğ. (2016)	Vücut Yerleşim Sensör	Günlük Aktivite	WISDM	92%
Edel ve Köppe (2016)	Vücut Yerleşim Sensör	Günlük Aktivite	Kendi Veri Seti, Opportunity, Pamap2	90%
Gjoreski ve diğ. (2016)	Vücut Yerleşim Sensör	Günlük Aktivite	Kendi Veri Seti, Opportunity	74,6 % (ML), 75,5 % (DL)
Ha ve Choi (2016)	Vücut Yerleşim Sensör	Günlük Aktivite	MHEALTH	92%
Hammerla ve diğ. (2016)	Vücut Yerleşim, Nesne, Ortam Sensör	Günlük Aktivite, Parkinson Yürüyüş Donma Tespit	Opportunity, Pamap2, Daphnet Gait	93%
Inoue ve diğ. (2016)	Vücut Yerleşim Sensör	Günlük Aktivite	HASC	95%
Li ve diğ. (2016)	Nesne Yerleşimli Sensör	Yoğun Bakım Medikal Aktivite	Kendi Veri Seti	80%
Liu ve diğ. (2016)	Vücut Yerleşim Sensör	Günlük Aktivite	Kendi Veri Seti	99%
Ordóñez ve Roggen. (2016)	Vücut Yerleşim Sensör	Günlük Aktivite, İş Aktivitesi	Opportunity, Skoda, Pamap2	96%
Ravi ve diğ. (2016)	Vücut Yerleşim Sensör	Günlük Aktivite, İş Aktivitesi	Skoda, WISDM, Daphnet Gait, Active Miles	98%
Walse ve diğ. (2016)	Vücut Yerleşim Sensör	Günlük Aktivite	UCI Smartphone	98%
Wang ve diğ. (2016)	Vücut Yerleşim Sensör, Ortam Sensör	Günlük Aktivite, Konum Tespiti	Kendi Veri Seti	85%
Zebin ve diğ. (2016)	Vücut Yerleşim Sensör	Günlük Aktivite	Kendi Veri Seti	97%
Chen ve Xue (2015)	Vücut Yerleşim Sensör	Günlük Aktivite	Kendi Veri Seti	94%
Ha ve diğ. (2015)	Vücut Yerleşim Sensör	Günlük Aktivite, İş Aktivitesi	Skoda, MHEALTH	98%

Araştırma / Makale	Sensör Kullanım Şekli	Araştırma Uygulaması	Veri Seti	Başarı Oranı
	Vücut Yerleşim			
Hayashi ve diğ. (2015)	Sensör, Ortam Sensör	Günlük Aktivite	HASC	92%
Jiang ve Zin (2015)	Vücut Yerleşim Sensör	Günlük Aktivite	UCI Smartphone, USC-HAD, SHO	100%
Lane ve diğ. (2015)	Ortam Sensörü	Günlük Aktivite	Kendi Veri Seti	85%
Ronao ve Cho (2015)	Vücut Yerleşim Sensör	Günlük Aktivite	UCI Smartphone	96%
Vepakomma ve diğ. (2015)	Vücut Yerleşim, Nesne, Ortam Sensör	Günlük Aktivite	Kendi Veri Seti	93%
Yang, ve diğ. (2015)	Vücut Yerleşim, Nesne, Ortam Sensör	Günlük Aktivite	Opportunity, ActRecTut	96%
Zhang ve diğ. (2015a)	Vücut Yerleşim Sensör	Günlük Aktivite	Kendi Veri Seti	94%
Zhang ve diğ. (2015b)	Vücut Yerleşim Sensör (Telefon)	Günlük Aktivite	Kendi Veri Seti	99%
Zhang ve diğ. (2015c)	Vücut Yerleşim Sensör	Günlük Aktivite	Opportunity, USC- HAD, DSADS	83%
Fang ve Hu (2014)	Nesne Yerleşim Sensör, Ortam Sensörü	Günlük Aktivite	Kendi Veri Seti	63% - 94%
Zeng ve diğ. (2014)	Vücut Yerleşim, Nesne, Ortam Sensör	Günlük Aktivite, İş Aktivitesi	Opportunity, Skoda, Actitracker	88%

Derin öğrenme kullanılarak yapılan çalışmalar incelendiğinde ağırlıklı olarak hazır veri setleri kullanıldığı görülmektedir. Bununla birlikte kendi veri setini kullanılan çalışmaların ise ağırlıklı sağlık sektörü çalışmalarında parkinson hastalarında yürüyüş donma tespiti, yürüyüş bozuklukları tespiti, nefes alma oranı belirleme gibi çalışmalar olduğu tespit edilmiştir.

Cheng ve diğ. (2017) çalışmalarında 44 parkinson hastası ve benzer yaş grubunda 35 sağlıklı bireyin, akıllı telefondaki sensörler ile 20 Hz frekans ile sürekli olarak hareket verileri

kaydedilmiştir. Derin öğrenme LSTM ağı kullanılarak yürüyüş dahil 6 hareket tahminlendiği çalışmada %98 başarı oranı yakalanmıştır.

Lee ve diğ. (2017) yaptıkları çalışmada kullanıcıların akıllı telefonlarından toplanan üç eksenli ivmeölçer verilerini kullanarak yürüme, koşma ve hareketsiz kalma gibi üç insan etkinliği verisini akıllı telefon ivme ölçer sensörü kullanılarak topladılar. Araştırmacılar tarafından sağlanan akıllı telefonları ile 5 lisansüstü öğrenci ile yürüyüş, koşma ve hareketsiz kalma gibi üç etkinliği 1 Hz Frekans ile kaydettiler. Öğrenciler hareket verilerini kaydederken akıllı telefonları çeşitli pozisyonlarda (elde, cepte, çantada) taşımışlardır. Çalışmada toplam 2,377 saniyelik koşu, 3,588 saniyelik yürüme ve 3,934 saniyelik hareketsiz kalma süresi olmak üzere toplamda 9,899 saniye insan aktivitesi verisi toplanmıştır. Toplanan bu X, Y ve Z ivme verilerinden Random Forest algoritması ve CNN' ağı kullanarak yaptıkları çalışmada CNN ile % 92,71 random forest algoritması ile % 89,10 doğruluk oranına ulaşmışlardır.

Zhang ve diğ. (2017) çok modlu verilerden karmaşık eşzamanlı ekip çalışması etkinliklerini tanıyan etkili bir derin öğrenme yapısı olan Concurrent Activity Recognizer'ı (CAR) ismi verdikleri bir çalışma yapmışlardır. Bu çalışmada kinect derinlik videosunu ve 25 tür tıbbi nesne üzerindeki pasif RFID etiketlerinden gelen verileri kullanarak 35 farklı etkinliği % 84 ortalama doğruluk oranı ile tahmin etmişlerdir.

Gjoreski ve diğ. (2016) bileğe takılmış sensör ivme verileri ile makine öğrenmesi algoritmaları ve derin öğrenme ile günlük aktivite hareket tahmini yaparak sonuçları karşılaştırmışlardır. İki farklı hazır dataset kullanılan çalışmada makine öğrenmesi random forest algoritması ile % 74.6 doğruluk oranına ulaşılmışken, derin öğrenme CNN ağı ile %75.5 doğruluk oranına ulaşılmıştır.

Chen ve diğ. (2015) yaptıkları çalışmada 3 eksenli ivme sensörleri ile 8 adet günlük hareketi CNN ile %93,8 doğruluk ile tahmin etmişlerdir.

## **2.2. İNŞAAT SEKTÖRÜNDE İNSAN HAREKETİ TANIMLAMA**

İnşaat Sektöründe yapılan çalışmalar incelendiğinde görüntü ve ses tabanlı çalışmalar yer almakla birlikte sınırlı sayıda kinematik tabanlı aktivite belirleme çalışmalarda yer almaktadır. Kinematik tabanlı işçi hareketi belirleme çalışmalarının tamamının makine öğrenmesi algoritmaları ile yapılmış olup derin öğrenme tabanlı çalışmaya rastlanılmamıştır.

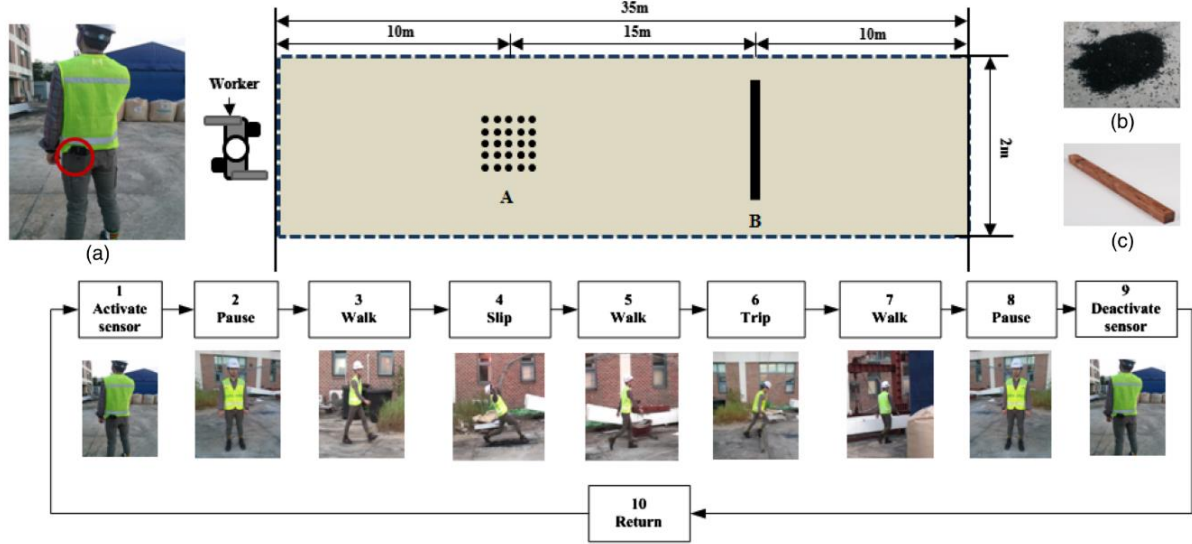
Ses verisi ile çalışmalar iş makineleri aktivitesi belirleme içeren, makine öğrenmesi tabanlı çalışmalardan oluşmaktadır. Ses ile işçi aktivitesi belirleme çalışması yer almamaktadır. Cheng ve diğ.(2019) sekiz adet farklı iş makinesinin sahada yaptıkları ses kayıtlarından SVM algoritması kullanarak %32 ile %86 arasında doğruluk oranı ile tahmin etmişlerdir. Cheng ve diğ. (2017) benzer şekilde 11 adet iş makinesinin aktivitelerini ses kayıtlarından SVM algoritması kullanarak %80 - %90 arası doğrulukla tahmin etmişlerdir. Yang ve diğ. (2015) kazıcı, kırıcı ve kesme işi yapan üç adet iş makinesini ses kayıtlarından SVM algoritması kullanarak %98 doğruluk oranında tahmin etmişlerdir. Her üç çalışmada incelendiğinde yoğun şekilde sinyal özellik çıkarımı içerdiği ve makine öğrenmesi SVM algoritması kullanmakta olduğu görülmüştür. Benzer şekilde Cheng ve diğ. (2016) ile Cao ve diğ. (2017) 4 çeşit iş makinesini ses verilerinden makine öğrenmesi ile %90 üzeri doğrulukla tespit etmişlerdir.

İnşaat sektöründe görüntü verilerinden yapılan çalışmalar ise ağırlıklı kamera görüntülerinden toprak hareketi miktarının tespiti, toprak yükleme miktarı tespiti ve iş güvenliği tehlikeli hareket tespiti çalışmalarından oluşmaktadır (Gong ve Caldas (2011);Azar ve diğ. (2012); Fard ve diğ (2013); Kim ve diğ. (2017); Bögler ve diğ. (2017); Kim ve diğ. (2018);Kim ve Chi (2019)).

İnşaat sektöründe kinematik tabanlı işçi aktivitesi tanımlama ile ilgili literatür taramada bulunan ilk çalışma Gustavo Cezar (2014) tarafından Stanford Üniversitesinde araştırma projesi olarak yapılmıştır. Bu çalışmada 3 işçi tarafından yapılan çekiç vurma, testereyle kesme, süpürme ve delme olmak üzere 4 adet aktivite 25 Hz frekansta aktif kolun bileğine takılan akıllı saat ile kaydedilmiştir. Kaydedilen veriler 1,6 sn. lik 40 adet bölüme ayrılmış ve 46 adet özellik çıkarımı yapılarak 5 farklı makine öğrenmesi algoritması uygulanmıştır. Bu çalışmada en yüksek %91 doğruluk oranına ulaşılmıştır.


Lim ve diğ. (2016) yaptıkları çalışmada 3 erkek denek bel hizasında pantolonun cebine yerleştirdikleri bir akıllı telefon ile 35 m. lik bir platform üzerinde 100 Hz. Frekansta yürüme, kayma ve sendeleme olmak üzere üç adet aktivite gerçekleştirmişlerdir. Sonrasında çalışmada toplanan sensör verileri 240 adet gruplara ayrılarak ( 100 Hz. Frekans ile 2,4 sn) ayrılarak her xyz eksenindeki üç sensör verisinin kareleri alınarak toplanarak karekökleri alınmıştır. Böylece 3 eksenindeki veri tek sensör verine çevrilmiştir. Sonrasında ise bu 240 sensör veri grubuna ilişkin aritmetik ortalama, standart sapma ve tepe noktası hesaplanarak özellik çıkarımı yapılmış ve bu üç adet veri girdi olarak ANN ağına eğitim için verilmiştir. Çalışma sonucunda yürüme %100,

kayma %88, sendeleme %94 doğrulukla tahmin edilmiş olup sistem toplam doğruluk oranı verilmemiştir.



Şekil 2.4: Lim ve diğ. (2016) tarafından yapılan üç hareketi tanımlamaya ilişkin çalışma görüntüleri

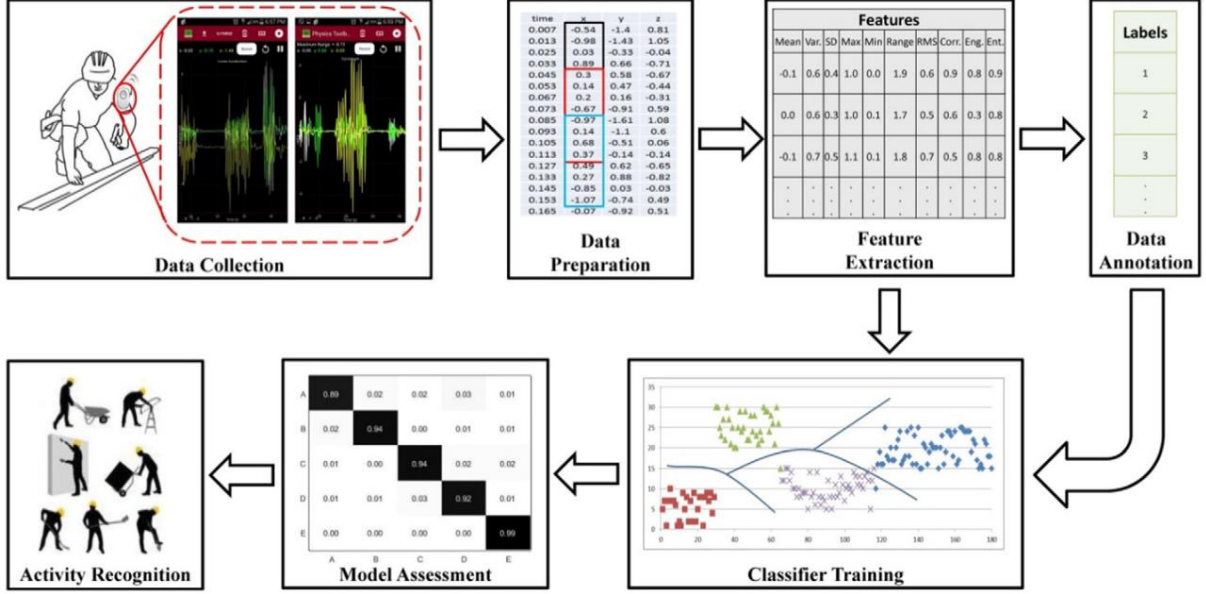
Akhavian ve Behzadan (2016) yaptıkları çalışmada 2 farklı deneğin kollarına bağladıkları akıllı telefon ile testere, çekiç ile vurma + anahtar çevirme, el arabasına yükleme + taşıma + yük boşaltma ve geri dönüş aktivitelerini 100 Hz frekansta kayıt altına almışlardır.



Şekil 2.5: Akhavian ve Behzadan (2016) tarafından yapılan hareket tanımlama çalışması görüntüleri

Verileri 128 adet 1,28 sn.lik gruplara ayırdıkları çalışmada toplam 54 adet özellik çıkarımı yapmışlardır. Çalışmada sınıflandırma algoritması olarak ANN, karar ağacı (decision tree), K-

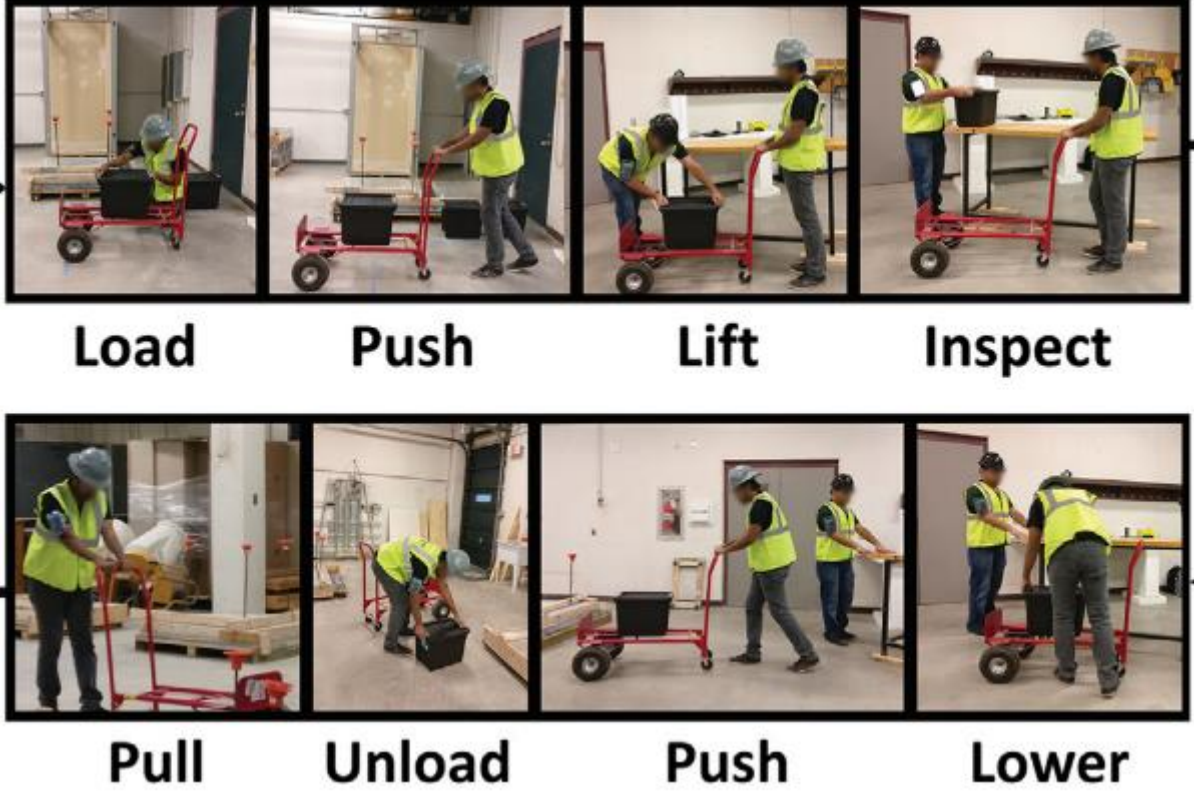
en yakın komşu (KNN), lojistik regresyon (logistic regression), destek vektör makinası (SVM) kullanılmıştır.



Şekil 2.6: Akhavian ve Behzadan (2016) tarafından yapılan çalışmanın akış şeması

Çalışmada ayrıca farklı denekler için ayrı ayrı ve her deneğin verileri birleştirilerek iki şekilde eğitim gerçekleştirilmiş ve sonuçları sunulmuştur. Buna göre her deneğin kendi veri seti ile yapılan çalışmada %87-%97 arası başarı sağlanmışken, her iki denek verileri birleştirilerek yapılan çalışmada bu oran % 62-%96 arasında değişmiştir. Akhavian ve Behzadan (2018) aynı veri setini kullanarak ilave model ekleyerek güncelledikleri çalışmada %90,09 - %99,28 doğruluk oranını yakalamışlardır.

Nath ve diğerleri (2018) işçilerdeki kas ve iskelet sistemi bozuklukları açısından riskli aktivitelerin tespiti amacıyla bir çalışma yapmışlardır. 2 işçinin kol ve beline bağlanan akıllı telefonlar 35-190 Hz aralığında yapılan yükleme, indirme, kaldırma, itme, çekme hareketleri sağlık açısından risklerine göre üç kategoriye ayrılmıştır. Yapılan aktivitenin risksiz (0), riskli (1) ve çok riskli (2) olarak gruplandırıldığı ve 12 adet özellik çıkarımı ile SVM algoritması kullanılan çalışmada %90,2 doğruluk oranı yakalanmıştır. Burada çalışmada araştırmacılar bu tahmin ile işçinin çalışma esnasında hangi risk grubundaki çalışmaya ne kadar süre maruz kaldığını tespit etmişlerdir.



Şekil 2.7: Nath ve diğ. (2018) kas sistemi açısından riskli hareketlerin tespit çalışması görüntüleri Ryu ve diğ. (2019) laboratuvar ortamında 10 tuğla duvar işçisinin duvar örerken yaptıkları işi 4 ayrı kategoriye ayırarak aktif alışan koldaki akıllı saat ile yapılan işi tahmin etmişlerdir. Duvar işindeki bu alt dört aktivite harcın yayılması, tuğla getirme ve yerleştirme, tuğlaları hizalama ayarlama ve kalan harçları temizleme olarak belirlenmiştir. Toplanan verileri 1-4 sn. arası gruplara ayırarak 30 özellik çıkarımı yaptıkları çalışmada 4 farklı makine öğrenmesi algoritması kullanmışlardır. En iyi sonuçları 4 sn.lik gruplarda aldıkları çalışmada en yüksek %88,10 doğruluk oranına ulaşmışlardır.

Yang ve diğ. (2019) çalışanların fiziksel iş yükü tespiti amacıyla makine öğrenmesi tabanlı sınıflandırma çalışma yapmışlardır. Ryu ve diğ. (2019) yapmış olduğu çalışmada tuğla duvar işçisinin yapmış olduğu alt işleri tespit ederken, bu çalışmada benzer şekilde demir işçilerinin yapmış olduğu demir yerleştirme, kesme, kaldırma gibi 8 adet alt iş kırılımı tespitine yönelik gerçekleştirilmiştir. Çalışma sonucunda bu tespiti kullanarak işçilerin fiziksel iş yükü tespiti hedeflenmiştir. Makine öğrenmesi SVM algoritmasının kullanıldığı çalışmada %94-%99 aralığında doğruluk oranı yakalanmıştır.

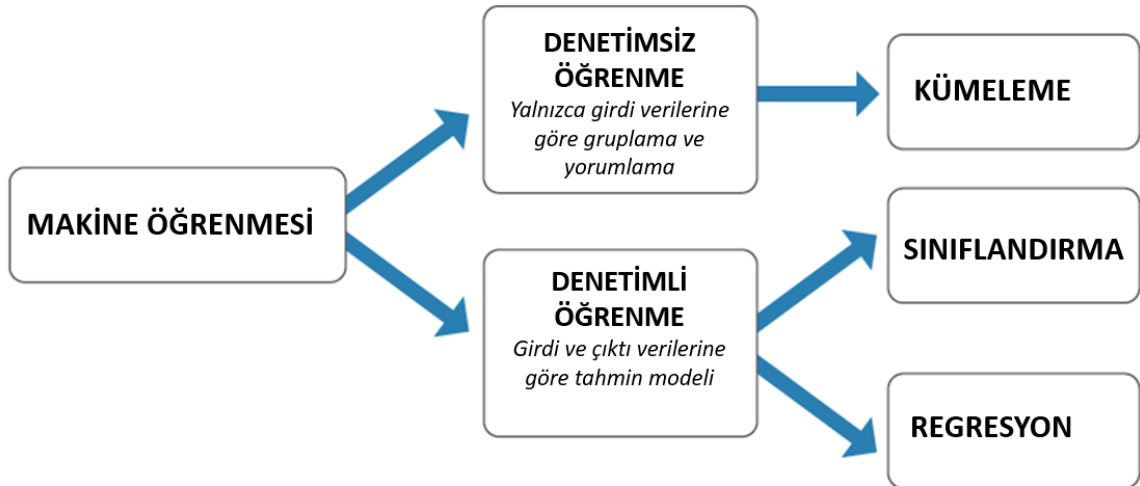


### 2.3. YAPAY ZEKA MAKİNE ÖĞRENMESİ

Yapay zeka tipik olarak, bir makinenin algılama, akıl yürütme, öğrenme, çevre ile etkileşim, problem çözme gibi insan zihniyle ilişkilendirdiğimiz bilişsel işlevleri gerçekleştirme yeteneği olarak tanımlanır (Chui, Kamalnath ve McCarthy, 2018). Yapay zekanın başlangıcı genel olarak Alan Turing tarafından Ekim 1950 'de yayınlanan ""Makineler düşünebilir mi? sorusunu sorgulamayı öneriyorum" cümlesi ile başlayan "Computing machinery and intelligence" isimli makalesi kabul edilmektedir (Turing, 1950).

Makine öğrenimi, bir sistemin açık programlama yerine verilerden öğrenmesini sağlayan bir yapay zeka biçimidir (Arthur Samuel, 1959). Makine öğrenimi, verileri iyileştirmek, açıklamak ve sonuçları tahmin etmek için verilerden yinelemeli olarak öğrenen çeşitli algoritmalar kullanır. Veri biliminde bir algoritma, istatistiksel işlem adımlarının bir dizisidir. Makine öğreniminde, algoritmalar, yeni verilere dayalı kararlar ve tahminler yapmak için büyük miktarda verideki kalıpları ve özellikleri bulmak üzere eğitilir. Algoritma ne kadar iyi olursa, daha fazla veri işledikçe kararlar ve tahminler o kadar doğru olur. Bir makine öğrenimi modeli, makine öğrenimi algoritmanızı verilerle eğittiğinizde üretilen çıktıdır. Eğitimden sonra, yeni veriler verdiğinizde, veriden öğrendiği ile size çıktıyı vermektedir. (Hurwitz ve Kirsch, 2018).

Makine öğrenimi iki tür teknik kullanır (*Introducing Machine Learning*, 2020):



Şekil 2.8: Makine öğrenmesinde kullanılan teknikler (*Introducing Machine Learning*, 2020)

### 1. Denetimli Öğrenme :

Denetimli öğrenmede hem girdi hem de çıktılar eğitim modeline veri olarak aktarılır. Gelecekteki çıktıları tahmin edebilmek için bilinen girdi ve çıktı verileri üzerinde bir model eğitmektedir. Denetimli makine öğreniminin amacı, belirsizliğin olduğu durumlarda kanıta dayalı tahminler yapan bir model oluşturmaktır. Denetimli bir öğrenme algoritması, bilinen bir dizi girdi verisini ve verilere (çıktıya) bilinen yanıtları alır ve yeni verilere yanıt için makul tahminler oluşturmak için bir model eğitir.

Denetimli öğrenme, tahmine dayalı modeller geliştirmek için sınıflandırma ve regresyon tekniklerini kullanır.

- Sınıflandırma teknikleri verilerden farklı sonuçları tahmin eder. Sınıflandırma modelleri, girdi verilerini kategorilere ayırır.
- Regresyon teknikleri girdi verilerinden sürekli tepkileri tahmin eder.

### 2. Denetimsiz Öğrenme : Sadece girdi verilerini içermektedir. Bu girdi verilerinin verideki deseni veya iç yapıları bulmak için model eğitilmektedir.

Makine öğrenmesi süreci temel olarak aşağıdaki 5 adımdan oluşmaktadır.

**Veri toplama:** Makine öğrenmesinin ilk ve en temel adımını çeşitli kaynaklardan veri toplanması oluşturmaktadır. Toplanan bu veriler öğrenmenin temelini oluşturur. İlgili verilerin çeşitliliği, yoğunluğu ve hacmi, makine öğrenmesinin başarısını etkileyen önemli faktörler arasındadır.

**Verilerin Hazırlanması ve Özellik Çıkarımı:** Kullanılan verilerin kalitesi ve sisteme uygunluğu öğrenme başarısını etkilemektedir. Veri kalitesini artırmak ve ardından eksik veriler ve aykırı değerlerin işlenmesi gibi sorunları gidermek için adımlar atmak gerekir. Bozuk verilerin ayrılması, gerektiğinde verilerden özellik çıkarımı ve verilerin eğitime hazırlanması bu adımda yapılmaktadır. Ayrıca hazırlanan verilerin test ve eğitim verisi olarak ayrılması da bu adımda yapılmaktadır.


**Modelin Seçimi ve Eğitilmesi:** Bu adım modele uygun algoritmayı seçmeyi içerir. Ayrıca seçilen modele uygun eğitim parametreleri de bu adımda belirlenir. Eğitim verileri modele verilerek eğitim gerçekleştirilir.

Modelin değerlendirilmesi: Bu adımda eğitilen modele doğruluğu ölçmek için test verileri yüklenir ve sonuç değerlendirilir.

Performansın iyileştirilmesi: Bu adım bir önceki adımdaki doğruluk oranına bağlı olarak tamamen farklı bir model seçmeyi veya verimliliği artırmak için daha fazla değişken eklemeyi içerebilir. Doğruluğu artırmak için veri, algoritma, parametler vs. değiştirilmesi amacıyla önceki adımlara dönerek süreç tekrar işletilir.

## 2.4. DERİN ÖĞRENME

Derin öğrenme, doğrudan görüntülerden, metinlerden, sestan veya sinyal verilerinden öğrenen bir tür makine öğrenmesidir. Yapay Sinir Ağları (YSA), nöronlar veya algılayıcılar olarak adlandırılan çok sayıda basit unsurdan oluşan bir öğrenme sistemidir. Derin öğrenme bir yapay sinir ağı mimarisi kullanılarak gerçekleştirilir. "Derin" terimi, ağıdaki katmanların sayısını ifade eder ve ne kadar çok katman olursa ağ o kadar derin olur. Geleneksel sinir ağları yalnızca üç katman içerirken, derin ağlar yüzlerce katmana sahip olabilir (*Introducing Deep Learning with MATLAB, 2020*).



Şekil 2.9: Geleneksel ve derin sinir ağları (*Introducing Deep Learning with MATLAB, 2020*)

Derin öğrenme ağları, aynı yapay sinir ağlarında olduğu gibi bir giriş katmanı, gizli katmandan ve bir çıktı katmanından oluşur. Derin Sinir ağlarının farkı çok fazla sayıda gizli katman içermesidir. Bu katmanlar düğümler veya nöronlar aracılığıyla birbirine bağlanır ve her gizli katman, önceki katmanın çıktısını girdi olarak kullanır.

Derin öğrenme modelleri içinde en fazla kullanılan derin öğrenme ağı türü olarak CNN ve RNN ön plana çıkmaktadır (Pouyanfar ve diğ., 2018). CNN, insan görsel korteksini simüle etmeye


dayanır ve bilgisayarla görme (görüntü tanıma) ve video tanıma için en çok tercih edilen sinir ağıdır (Shrestha ve Mahmood, 2019).

RNN, konuşma, el yazısı, metin ve bu tür uygulamalar gibi zaman serisi verileri için tasarlanmıştır. RNN, giriş verilerini sıralı olarak işlemek için tekrarlayan hesaplamalar kullanan yapıdaki döngüsel bağlantılardan yararlanır (Mosavi, Ardabili ve Várkonyi-Kóczy, 2020).

Literatür taramalarında, Makine Öğrenmesi algoritmaları ile beraber CNN insan hareketi tanımlamada en çok kullanılan yöntemler arasındadır. Bununla birlikte son dönemde RNN tabanlı LSTM ve GRU algoritmaları kullanan çalışmaların da artmaya başladığı görülmektedir.

#### 2.4.1. Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan sinir ağları (RNN), düğümler arasındaki bağlantıların yönlendirilmiş bir döngü oluşturduğu yapay sinir ağı sınıfıdır. Bu, dinamik zamansal davranış sergilemesine izin verir. İleri beslemeli sinir ağlarından farklı olarak, RNN'ler kendi giriş belleğini girdilerin sıralarını işlemek için kullanabilirler. (*Recurrent Neural Networks (RNN) Tutorial Using TensorFlow In Python - Edureka, 2019*)



Şekil 2.10 Tekrarlayan sinir ağı (RNN) yapısı (*Recurrent Neural Networks (RNN) Tutorial Using TensorFlow In Python - Edureka, 2019*)

$$h^{(t)} = g_h (W_i X^{(t)} + W_R h^{(t-1)} + b_h) \quad (2.1)$$

$$y^{(t)} = g_y (W_y h^{(t)} + b_y) \quad (2.2)$$

$X^{(t)}$  : t zamanındaki veri girdisi

$h^{(t)}$  : t zamanındaki gizli katman verisi

$h^{(t-1)}$  : t-1 zamanındaki gizli katman verisi

$y^{(t)}$  : t zamanındaki veri çıktısı

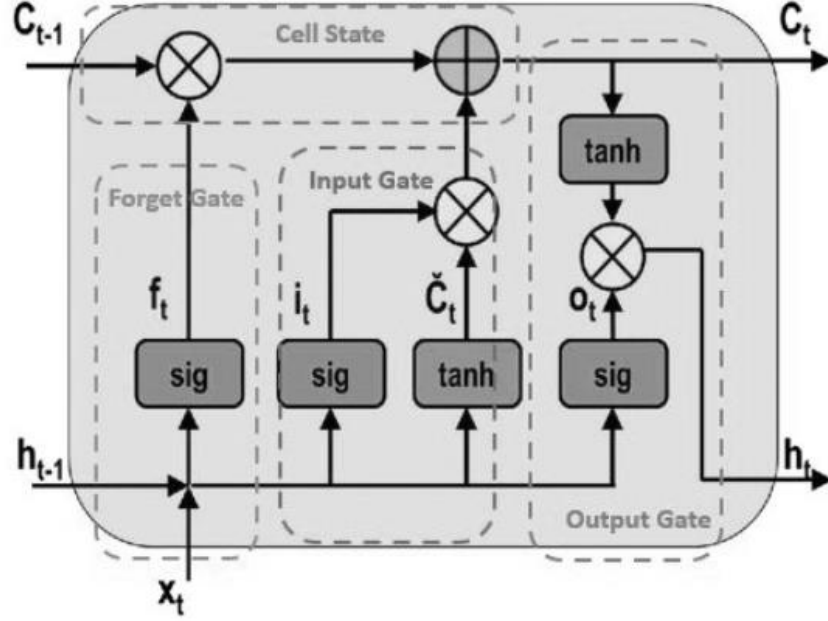
$W_y, W_R, W_i, b$  : ağırlık parametreleri

$g_h, g_y$  : aktivasyon fonksiyonları

Geleneksel bir sinir ağında tüm girdilerin ve çıktıların birbirinden bağımsız olduğu varsayılırken tekrarlayan sinir ağlarında ardışık bilgiler kullanılmaktadır. Tekrarlayan sinir ağlarında t zamanındaki  $y^{(t)}$  çıktısı daha önceki veri, çıktı ve hesaplamalara da bağlıdır. Teorik olarak, Tekrarlayan sinir ağları serilerdeki tüm verileri kullanabilmektedirler. Ancak pratikte kaybolan gradyan problemi nedeniyle ancak yakın dönemdeki verileri kullanmakla sınırlıdır. Tahmin ve gerçek değeri farkından oluşan hata değerinin geri yayılım ile ağırlıkların güncellenmesi sırasında gradyan değerleri geriye doğru ilerledikçe katlanarak küçülerek kaybolması, kaybolan gradyan sorununu ortaya çıkarmaktadır. (*RNN, LSTM ve GRU modellerinin incelemesi / by Mc V. / Medium, 2018*). Bu sorunun çözümü amacıyla 1997 yılında LSTM (Hochreiter ve Schmidhuber, 1997) ve GRU (Cho *vd.*, 2014) ağları geliştirilmiştir.

#### 2.4.2. Uzun Kısa Süreli Bellek Ağları (LSTM)

Hochreiter and Schmidhuber (1997) tarafından kaybolan gradyan sorununa çözüm olarak Long Short-Term Memory adında bir yöntem önerilmiştir. LSTM uzun vadeli bağımlılıkları öğrenebilen özel bir Tekrarlayan Sinir Ağı türüdür. LSTM ağında bir ana hücre içinde taşıyıcı bantlar ve yeni bilgilerin bir sonraki adıma geçip geçemeyeceğini kontrol eden kapılar yer almaktadır. LSTM hücresi, hücre durumu(C), unutma kapısı(f), giriş kapısı(i) ve çıkış kapısı(o) içermektedir.



Şekil 2.11 LSTM hücresi yapısı (*Introduction to LSTM Units in RNN / Pluralsight, 2020*)

C = Hücre Durumu

f = Unutma Kapısı

i = Giriş Kapısı

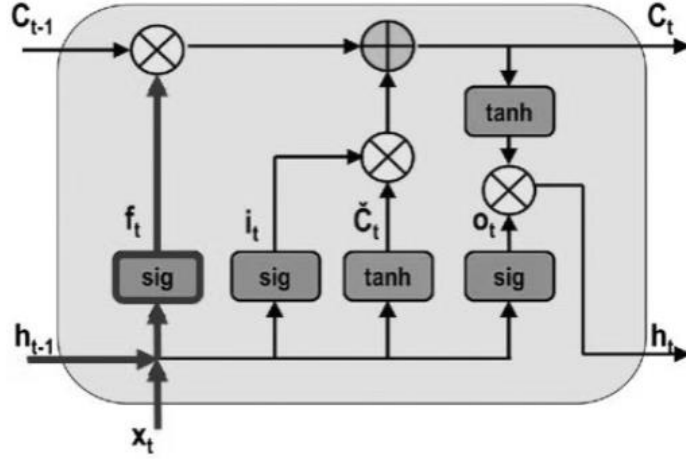
O = Çıkış Kapısı

h = Gizli Durum

$\sigma$  = Sigmoid Fonksiyon

$\tanh$  = Hiperbolik Tanjant Fonksiyonu

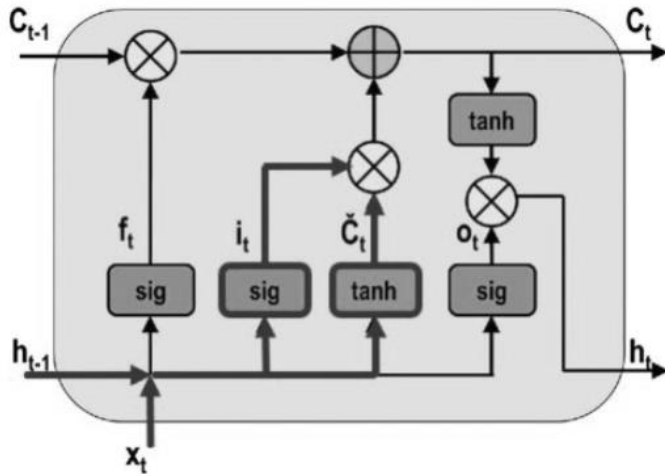
Unutma Kapısı (f) İşlemleri : Unutma kapısı, hangi bilgilerin dikkate alınması gerektiğine ve hangilerinin göz ardı edilebileceğine karar verir. Mevcut giriş verisi  $X(t)$  ve bir önceki gizli durumdan  $h(t-1)$ 'den gelen bilgiler sigmoid fonksiyonundan geçirilir. Sigmoid, 0 ile 1 arasında değerler üretir. Eski çıktının bir kısmının gerekli olup olmadığı sonucuna varır. Unutma kapısı, 0 ile çarpıldığında çıktıyı unuttur ve hücre durumundaki bilgileri 1 ile çarpıldığında tümünü bir sonraki adım için kaydeder. Bu  $f(t)$  değeri daha sonra hücre tarafından nokta-nokta çarpma için kullanılır.



Şekil 2.12 LSTM ağı unutmaya kapısı işlem süreci (*Introduction to LSTM Units in RNN / Pluralsight, 2020*)

$$f_t = \sigma (W_f [h_{t-1}, X_t] + b_f) \quad (2.3)$$

Giriş Kapısı (i) İşlemleri : Giriş kapısı, hücre durumunu güncellemek için ilk olarak, mevcut durum  $X(t)$  ve daha önceki gizli durum  $h(t-1)$  ikinci sigmoid fonksiyona geçirilir. Bu geçen değerler 0 (önemli) ile 1 (önemli değil) arasında yeni değerlere dönüştürülür. Sonrasında, gizli durum ve mevcut durumla ilgili aynı bilgiler tanh fonksiyonundan geçirilir. Ağı düzenlemek için, tanh operatörü -1 ile 1 arasındaki değerlere sahip bir vektör ( $C \sim (t)$ ) oluşur. Aktivasyon fonksiyonlarından üretilen çıktı değerleri birbirleriyle çarpılır.

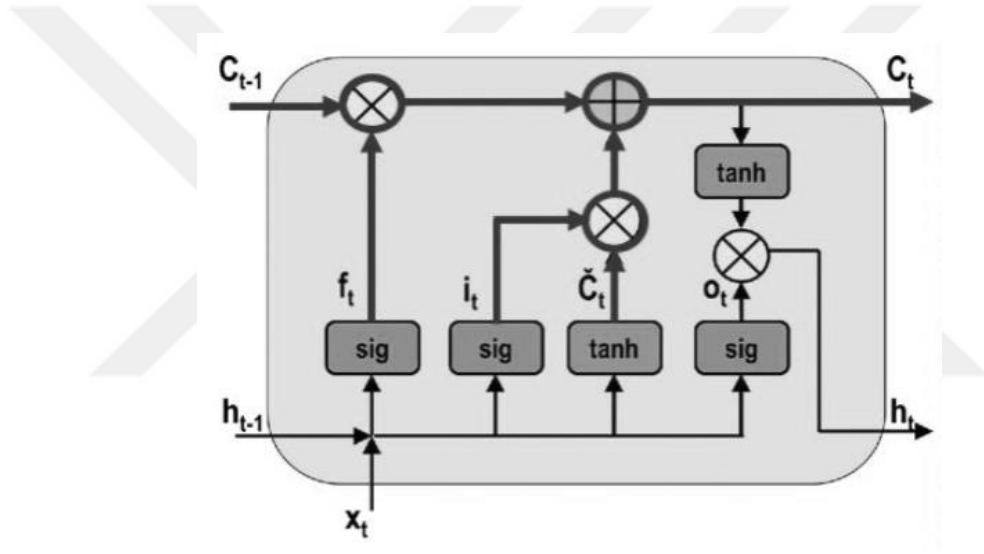


Şekil 2.13 LSTM ağı giriş kapısı işlem süreci (*Introduction to LSTM Units in RNN / Pluralsight, 2020*)

$$i_t = \sigma (W_i * [h_{t-1}, X_t] + b_i) \quad (2.4)$$

$$C \sim_t = \tanh (W_c * [h_{t-1}, X_t] + b_c) \quad (2.5)$$

Hücre Durumu (C) İşlemleri : Bu adımda yeni durumda oluşan bilgilerin hesaplanarak hücre içinde saklanması adımdır. Önceki hücre durumu C (t-1) unutmaya vektörü  $f(t)$  ile çarpılır. Sonuç 0 ise, değerler hücre durumunda düşecektir. Daha sonra ağ, giriş vektörü  $i(t)$  'nin çıkış değerini alır ve nokta-nokta toplama gerçekleştirir, bu da ağa yeni bir hücre durumu C (t) vererek hücre durumunu günceller.




Şekil 2.14 LSTM ağı hücre durumu işlem süreci (*Introduction to LSTM Units in RNN | Pluralsight, 2020*)

$$C_t = f_t * C_{t-1} + i_t * C \sim_t \quad (2.6)$$

Çıktı Kapısı (o) İşlemleri : Çıkış kapısı, sonraki gizli durumun değerini belirler ve önceki girişler hakkında bilgi de içerir. Öncelikle mevcut durum ve önceki gizli durumun değerleri üçüncü sigmoid fonksiyona aktarılır. Daha sonra hücre durumundan üretilen yeni hücre durumu, tanh fonksiyonundan geçirilir. Bu çıktıların ikisinin çarpımından oluşan nihai değere bağlı olarak, gizli durumun hangi bilgileri taşınması gerektiğine karar verilmiş olur. Bu gizli durum tahmin için kullanılır.





Şekil 2.15: LSTM ağı çıktı kapısı işlem süreci (*Introduction to LSTM Units in RNN | Pluralsight, 2020*)

$$O_t = \sigma (W_o * [h_{t-1}, X_t] + b_o) \quad (2.7)$$

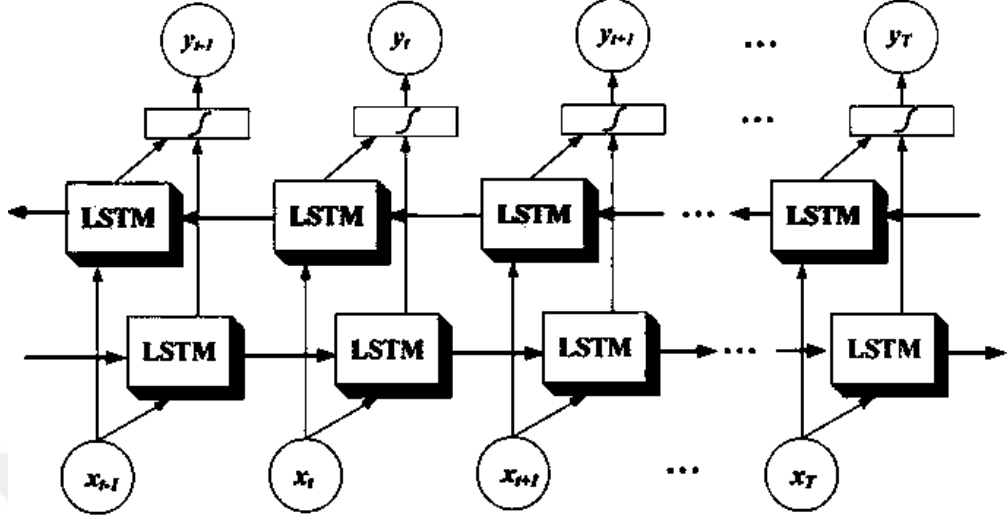
$$h_t = O_t * \tanh (C_t) \quad (2.8)$$

Sonuç olarak yeni hücre durumu ve yeni gizli durum bir sonraki adım adıma taşınır. Özetle, unutmaya kapısı önceki adımlardan hangi ilgili bilgilerin gerekli olduğunu belirler. Giriş kapısı, geçerli adımdan hangi ilgili bilgilerin eklenebileceğine karar verir ve çıkış kapısı ile bir sonraki gizli duruma geçecek veri belirlenmiş olur.

LSTM ağları yaygın olarak zaman serisi tahminleri, konuşma tanıma, el yazısı tanıma ve video görüntü tanıma kullanıldığı görülmektedir.

### 2.4.3 Çift Yönlü Uzun Kısa Süreli Bellek Ağları (BiLSTM)

BiLSTM ağlarının temeli Schuster ve Paliwal (1997) tarafından sıralı verileri iki ayrı RNN gizli katmanıyla hem ileri hem de geri yönde işleyen çift yönlü RNN çalışmasına dayanmaktadır. Çift yönlü LSTM, LSTM ağının bir kombinasyonudur. BiLSTM ağında birbirine paralel iki adet bağımsız LSTM ağı yer almaktadır. Bu ağlardan bir tanesi ileri yönlü verileri işlerken diğeri geri yönlü işlemektedir. Böylece LSTM sadece önceki verilerden sonuç üretirken, BiLSTM hem geçmiş hemde gelecekteki verileri dikkate alarak sonuç üretmektedir (Cui ve diğ., 2020). Çift yönlü LSTM'nin yapısı aşağıda gösterilmiştir (A.Raghav, 2019).



Şekil 2.16: Çift yönlü uzun kısa süreli bellek ağı yapısı (Murad ve Pyun, 2017)

Literatür taramasında da BiLSTM ile daha başarılı sonuçlar elde edildiği görülmektedir. Siami-Namini, Tavakoli ve Namin (2019) LSTM ve BiLSTM ağları kullanarak yaptıkları çalışmada aynı veri seti için BiLSTM ağının doğruluk oranının LSTM ağına oranla %37,78 daha fazla başarılı olduğunu bildirmişlerdir.

Ordóñez ve Roggen (2016) SKODA veri seti kullanarak yapmış oldukları insan hareketi tanıma çalışmasında CNN ile % 88,40 başarı oranı yakalamışken LSTM ile yaptıkları çalışmada %95,80 başarı oranını yakalamışlardır.

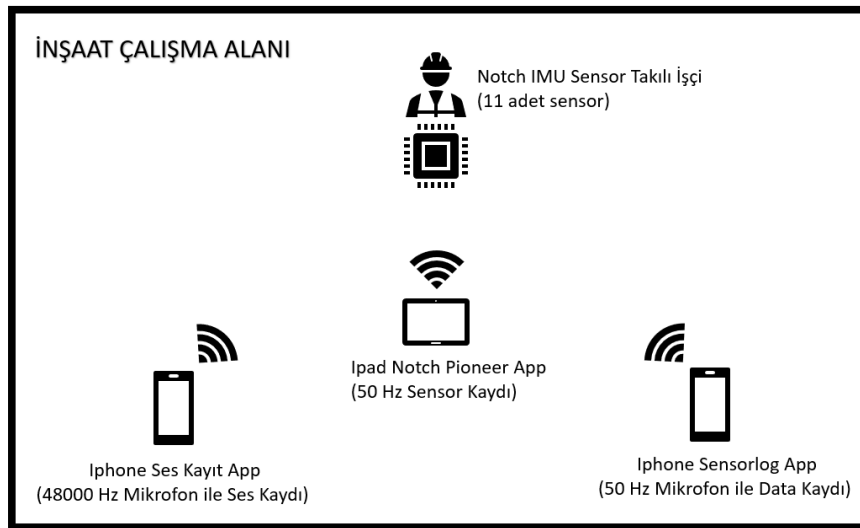
### 3. MALZEME VE YÖNTEM

#### 3.1. VERİ TOPLAMA YÖNTEMİ

Tez çalışması kapsamında temel olarak IMU sensörlerden elde edilen verilerin işlenerek aktivite tahmini yapılması hedeflenmiştir. Veri toplama işlemi ilk önce iki usta ile belirlenen 6 adet iş kalemi için yapılmıştır. Bu aşamada sadece 11 adet IMU sensör kullanılarak ölçüm yapılmıştır. Daha sonrasında tez sürecinde yazılan programın beklenen hedefe ulaşması ile çalışmaya ses verilerinin eklenmesi, ayrıca çalışmaya farklı ustalar ekleyerek veri miktarının artırılması yönünde çalışma genişletilmiştir. Böylece toplanan verinin artması yanında farklı ustaların iş yapış şekli ile derin öğrenme ağının performansının ölçülmesi hedeflenmiştir.

Bu hedef doğrultusunda sensör verilerine ilave olarak iş yapılan ortamdaki ses verisi iki farklı yöntemle kaydedilmiştir. Bunlardan ilki bir IOS uygulaması olan Sensorlog programı ile telefon mikrofonu üzerinden ortamdaki sesin tepe noktası ve ortalaması dB cinsinden kayıt altına alınmıştır. Bunun yanında yine iş yapılan ortamdaki ses cep telefonu mikrofonu üzerinden .wav dosyası olarak kaydedilmiştir.

Böylece ilk set veriler sadece iki adet usta ve 6 farklı iş aktivitesine ait sensör verilerinden oluşurken ikinci set çalışma beş farklı ustaya ait 6 farklı iş aktivitesi için hem sensör hem ses verilerinden oluşmaktadır.



Şekil 3.1: İnşaat çalışma alanı ve veri toplama araçları

### 3.2. VERİ TOPLAMADA KULLANILAN ARAÇ VE YAZILIMLAR

#### 3.2.1. Hareket Sensör Verileri Toplanmasında Kullanılan Araç ve Yazılımlar:

Hareket verileri toplanmasında, Notch Interfaces Inc. firması tarafından vücut hareketlerinin 3D görüntüye çevrilmesi amacıyla üretilmiş Notch sensörler kullanılmıştır. Bir sette 6 adet sensör yer almakta olup çalışma kapsamında 2 set toplam 12 adet sensör temin edilmiştir. Her bir IMU sensör seti içinde ivme ölçer, jireskop ve manyetometre sensörleri yer almaktadır. İşçinin vücudunda belirlenen noktalarına bir lastik bant ile bağlanan sensörler, tablet veya telefon üzerinden Notch Pioneer yazılımı ile gerekli ayarlar yapılarak kayıt başlatılmaktadır.



Şekil 3.2 Hareket veri toplanmasında kullanılan sensörlere ait görüntüler (*Wearnotch / Wearable 3D motion capture / Free apps / Mobile SDK / Template Code, 2017*)

Sensörlerdeki donanım ve Notch yazılımı 5Hz, 10Hz, 20Hz, 40Hz, 50Hz, 100Hz, 125Hz, 200Hz, 333Hz, 500Hz olmak üzere 10 farklı frekansta kayıt imkanı sunmaktadır. Çalışma kapsamında veriler 50 Hz (saniyede 50 adet kayıt) kullanılmıştır. Kayıt sonrası her bir sensör üzerine kaydedilmiş veriler bluetooth kablosuz bağlantı ile tablet veya telefona aktarılmaktadır. Bu program vasıtasıyla internete yüklenen verilerden 3D hareket animasyonu oluşturulmaktadır. Ayrıca program yazılım geliştiricilerin kullanması amacıyla .csv formatında sensörlerden elde edilen ham verileri sağlamaktadır. Tez çalışması kapsamında bu ham sensör verileri kullanılarak yazılım geliştirilmiştir. Kayıt sonrası aşağıda sunulan veriler .csv formatında elde edilmektedir.

- Eklem Açıları
- Sensörün bağlı olduğu vücut parçasına ilişkin pozisyon
- X,Y,Z ekseninde sensör ivmesi
- X,Y,Z ekseninde sensör dönüş hızı

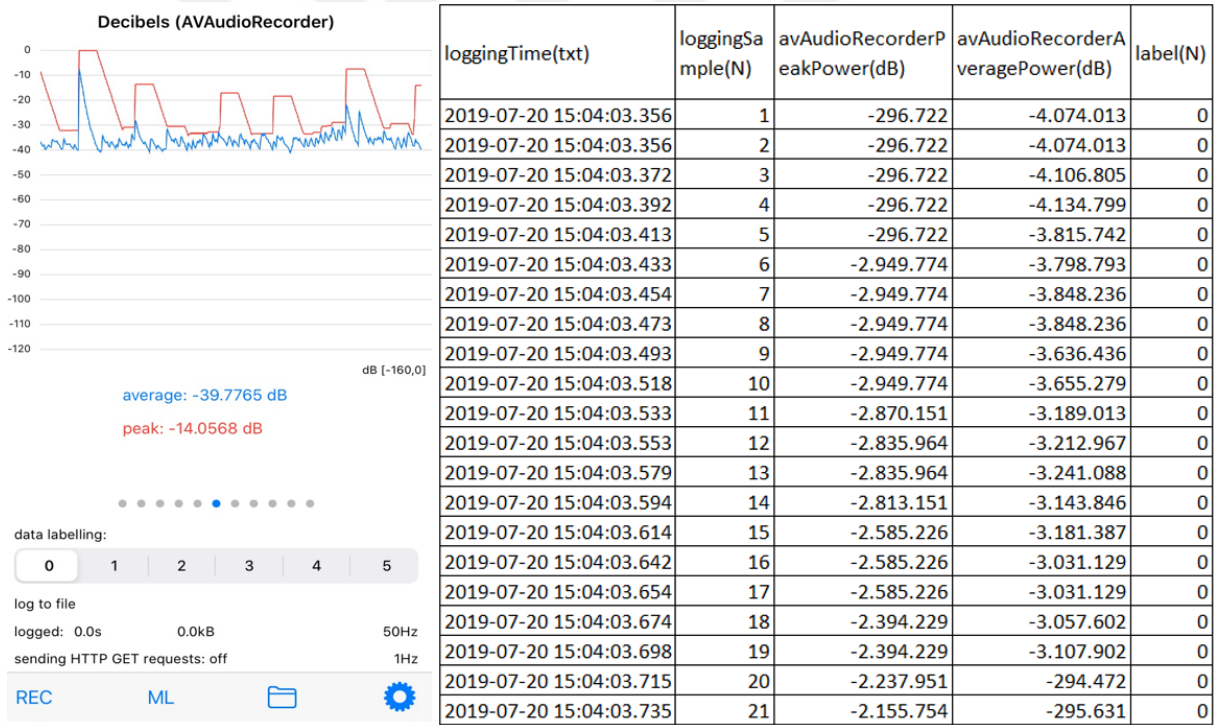
Tez çalışmasında kullanılan boya aktivitesinde sağ önkol üzerindeki sensöre ait 0,3 sn. lik ivme ve dönüş hızına ilişkin veri örnek .csv tablosu aşağıda sunulmuştur.

Time [s]	Acc_x [m/s^2]	Acc_y [m/s^2]	Acc_z [m/s^2]	Gyro_x [1/s]	Gyro_y [1/s]	Gyro_z [1/s]
0.000	0.043	0.117	0.017	-0.030	-0.013	-0.004
0.020	-0.011	0.122	-0.002	-0.024	-0.013	-0.006
0.040	-0.086	0.103	-0.035	-0.019	-0.011	-0.008
0.060	-0.125	0.060	-0.038	-0.015	-0.008	-0.013
0.080	-0.088	0.029	-0.001	-0.015	-0.007	-0.014
0.100	-0.019	0.040	0.021	-0.020	-0.008	-0.016
0.120	0.043	0.089	0.010	-0.026	-0.008	-0.017
0.140	0.061	0.127	-0.012	-0.031	-0.018	-0.016
0.160	0.039	0.117	-0.032	-0.027	-0.021	-0.015
0.180	0.012	0.079	-0.049	-0.025	-0.021	-0.018
0.200	-0.017	0.049	-0.069	-0.029	-0.030	-0.020
0.220	-0.057	0.045	-0.104	-0.032	-0.033	-0.018
0.240	-0.104	0.045	-0.120	-0.029	-0.040	-0.017
0.260	-0.154	0.030	-0.085	-0.024	-0.056	-0.020
0.280	-0.166	0.019	-0.028	-0.020	-0.069	-0.025
0.300	-0.110	0.020	0.004	-0.017	-0.059	-0.030

Şekil 3.3: Sensörlerden elde edilen verilere ilişkin örnek ekran görüntüsü

### 3.2.2. Ses Verileri Toplanmasında Kullanılan Araç ve Yazılımlar

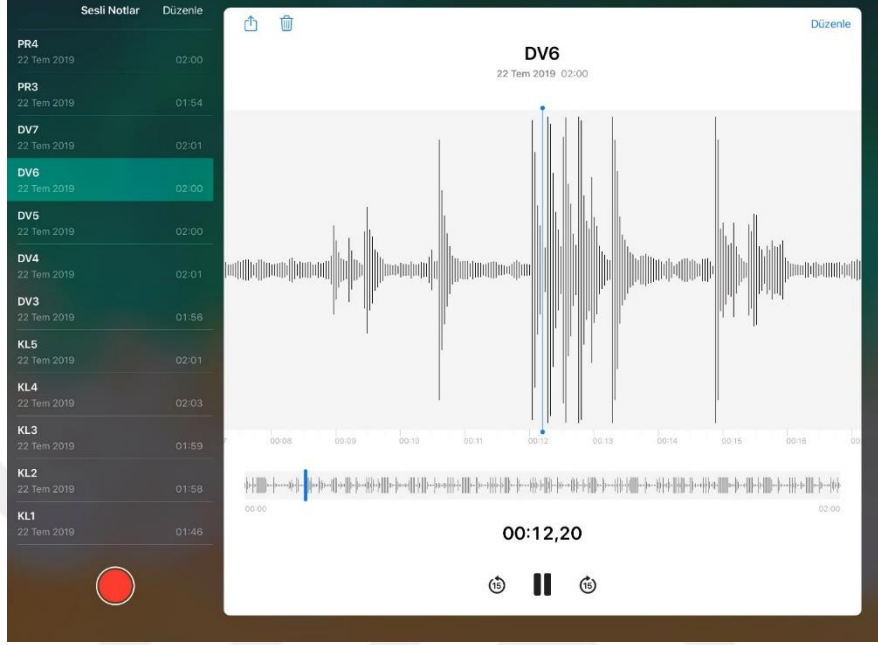
Ses verileri toplanması aşamasında, işin yapımı sırasında sabit iki noktadan cep telefonu mikrofonu ile ses verileri kaydedilmiştir. Birinci olarak Iphone 6S model telefonda Telefonun bir tanesinde Sensorlog (*SensorLog*, 2021) yazılımı kullanılmıştır. İlgili yazılım telefon üzerinde yer alan sensör ve diğer araçları kullanarak ivme, yön, yer, rakım, basınç, ses şiddeti gibi değerleri belirlenen frekans aralığında kayıt altına almaktadır. Tez çalışmasında programın sadece ses şiddeti kaydetme özelliği kullanılmıştır. Bu özellikte sesin şiddetinin dB cinsinden belirlenen frekansta en yüksek ve ortalama değerleri kayıt altına alınmıştır. Kayıtta Sensorlog programının 3.4 versiyonu kullanılmıştır. Kayıt sonrası elde edilen veriler .csv formatında veri işleme için kullanılabilir. Aşağıda Sensorlog programına ait ekran görüntüsü ve .csv formatında aktarılan datanın içeriği yer almaktadır.



Şekil 3.4: Ses verileri toplanmasında kullanılan Sensorlog yazılımına ait ekran görüntüleri (*SensorLog*, 2021)

İkinci olarak iş aktivitesi yapılan ortamdaki ses Iphone X model cep telefonu ile IOS içindeki yerleşik sesli notlar uygulaması ile kaydedilmiştir. Bu kayıt diğer ses kaydı ile eş zamanlı yapılmıştır. IOS sesli not uygulaması varsayılan ayar olarak sesi 48 kHz (48.000 Hz) frekansta ve .m4a formatında kaydetmektedir. Sonrasında kaydedilen bu ses dosyası işleme amacıyla

bilgisayara aktarılmıştır. Aşağıda duvar aktivitesine ilişkin yapılan ses kaydı görüntüsü sunulmuştur.



Şekil 3.5: IOS yerleşik sesli not yazılımı ile kaydedilen duvar işine ait ses verileri ekran görüntüsü

### 3.3. TEZ ÇALIŞMASI KAPSAMINDA BELİRLENEN İŞ AKTİVİTELERİ

Tez kapsamında aktivite tahmini için yapılacak olan çalışmada 6 adet iş grubu belirlenmiştir. Bu inşaat aktiviteleri;

1. Boya İşleri : Bu iş kapsamında işçi tarafından bir rulo yardımı ile duvar boya aktivitesi yapılmıştır. İşçiler iki eli ile tutmuş olduğu saplı boya rulosu ile belirlenen bir alanda boyama işlemini gerçekleştirmiştir.
2. Alçı Sıva İşleri : Bu iş kapsamında, sağ elinde sıva malası diğer elinde sıvacı küreği olan işçiler alçı sıva işlemini gerçekleştirmişlerdir.
3. Tuğla Duvar İşleri : Bu iş kapsamında işçi yanında stoklanmış olan tuğlayı alarak, yanındaki kovada bulunan harcı mala yardımı ile almakta, harcı sürdükten sonra tuğlayı diğer tuğlaya yapıştırarak mala ile daha iyi yapışması için tuğlaya vurmaktadır.
4. Seramik Döşeme İşleri : Bu iş kapsamında işçiler ilk önce seramik montajı yapacakları yüzeye daha önceden hazırlanmış seramik yapıştırıcısını seramik harcı tarağı ile sürmüşler,

sonrasında hemen yanlarındaki seramikten alarak yüzeye yapıştırmışlardır. Sonrasında seramiğin zemindeki yapıştırıcı harcı daha iyi tutması amacıyla plastik çekiç ile çeşitli noktalardan seramik üzerine vurmuşlardır.

5. Laminat Parke İşleri : Bu iş kapsamında işçiler yanında yer alan laminat parke plakasını mevcut parkeye kenetlemiş sonra parkenin daha iyi yerleşmesi amacıyla plastik aparatı yeni taktıkları parkeye geçirerek sağ ve soldan plastik çekiç ile vurarak parkenin daha iyi kenetlenmesini sağlamışlardır.

6. Ahşap Kalıp İşleri : Bu iş kapsamında işçiler yan taraflarında bulunan ahşap kalıp plakasını alarak duvarda yerine yerleştirdikten sonra çekiç ile kalıp üzerine çivi çakma işlemi gerçekleştirmişlerdir.

Seçilen işler incelendiğinde sıva ve boya işleri ayakta, parke ve yer seramik işleri yerde ve dizler üzerinde, kalıp ve tuğla duvar işleri eğilerek bir yerden malzeme alma sonrasında ayakta işin yapılması şeklinde gerçekleşmektedir. Bu durum sadece vücut pozisyonu ve hareketler olarak değerlendirildiğinde sıva ile boya, parke ve seramik, tuğla duvar ve kalıp işleri birbirine benzer yapıdadır. Bu vücut pozisyonu birbirine yakın aktiviteler seçilerek tez kapsamında yapılacak çalışma ile en zor şartlardaki tahmin doğruluk oranını görmek hedeflenmiştir.

### 3.4. VERİ TOPLAMA SÜRECİ

Bu bölümde seçilen inşaat aktivitelerine ait sensör ve ses verilerinin toplanma süreci aktarılmıştır. Sensor ve ses verileri olmak üzere toplanan ham verilere ilişkin toplam kayıt süresi ve kayıt sayıları aşağıda tabloda sunulmuştur.

Tablo 3.1: Sensör ve ses verilerine ait toplam kayıt veri özeti

Kayıt Tanımı	Kayıt Süresi (sn)	Toplam Kayıt Adet (Satır)	Toplam Veri (Adet)
IMU Sensor Kayıtları	6.952	347.623	45.886.236
Sensorlog Ses Kayıtları	3.583	179.156	358.312
IOS Ses Kayıtları	3.532	169.536.000	169.536.000
<b>Genel Toplam</b>	<b>14.067</b>	<b>170.062.779</b>	<b>215.780.548</b>

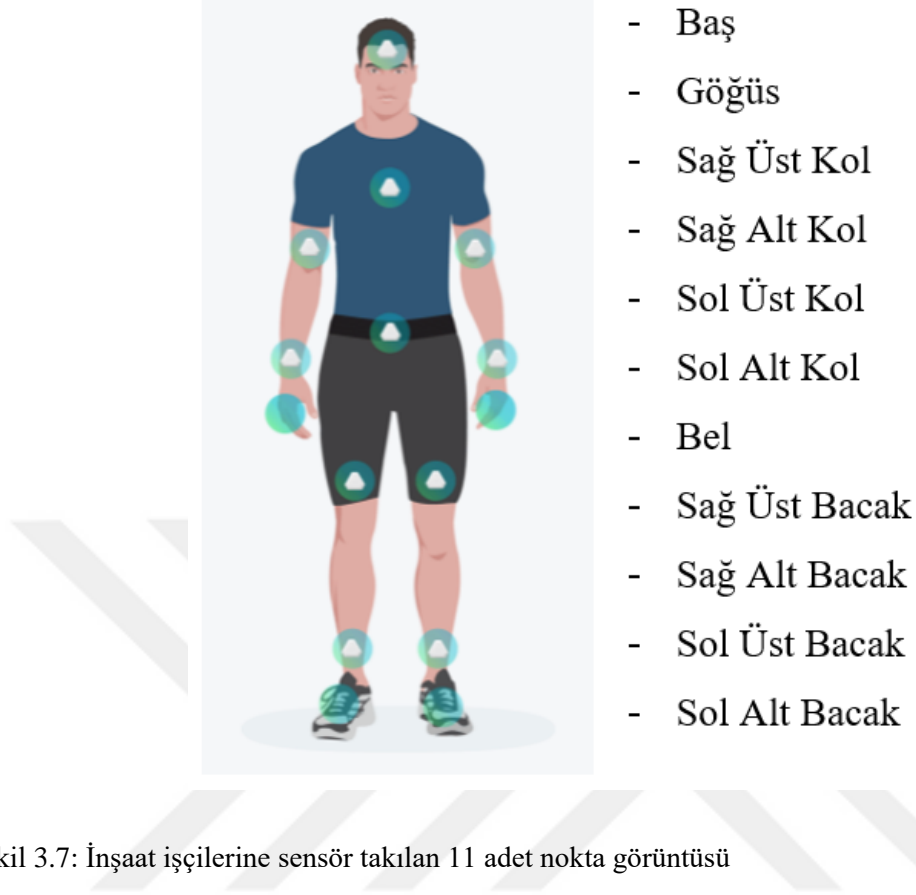


### 3.4.1. Sensör Verilerinin Toplanması

Tez çalışması kapsamında belirlenen aktivitelere ilişkin sensör verilerinin kayıt edilmesi amacıyla ilk önce vücut üzerinde hangi noktalara ait kayıtların hangi frekans aralığında toplanacağı ile analiz gerçekleştirilmiştir. Bu doğrultuda yapılan literatür çalışmasında aktivite tahminine ilişkin çalışmalarda kayıtların ağırlıklı olarak 50 -100 Hz frekans aralığında kayıt altına alındığı görülmüştür. Bu noktadan hareketle tez çalışmasında kayıt frekansı 50 Hz kullanılmıştır. Bununla birlikte kaydın aşağıda belirlenen noktalara yerleştirilen sensörler ile tüm vücut için alınması öngörülmüştür. Aşağıdaki resimde işçi üzerine yerleştirilmiş 11 adet sensöre ait noktalar gösterilmiştir.



Şekil 3.6: Veri toplama öncesi sensör takılmış inşaat ustaları



Şekil 3.7: İnşaat işçilerine sensör takılan 11 adet nokta görüntüsü

Sensör verileri ile x,y,z üç ekseninde ivme, dönüş yönü, dönüş hızı ve konum bilgileri elde edilmiştir. Her bir kayıta 11 farklı konumdaki sensörden saniyede 50 adet, 3 ekseninde, 4 farklı veri kayıt altına alınmıştır. Böylece her bir aktivite sırasında saniyede toplam 6600 adet veri kayıt altına alınmıştır. Aşağıda her bir aktivite kaydı sürecinde alınan kayıt süresi, kayıt adeti ve toplam veri sayısı gösterilmiştir.

Tablo 3.2: İş bazında sensör verilerine ait kayıtların detaylı özeti

No	İş Aktivitesi	ID	Kayıt Süresi (sn)	Kayıt Adet (Satır)	Toplam Veri (Adet)
1	Boya (paint)	BY1	300	14.985	1.978.020
2	Boya (paint)	BY2	240	11.988	1.582.416
3	Boya (paint)	BY3	120	5.993	791.076
4	Boya (paint)	BY4	120	5.993	791.076
5	Boya (paint)	BY5	120	5.993	791.076
6	Boya (paint)	BY6	120	5.993	791.076

No	İş Aktivitesi	ID	Kayıt Süresi (sn)	Kayıt Adet (Satır)	Toplam Veri (Adet)
7	Boya (paint)	BY7	120	5.993	791.076
8	Tuğla Duvar (brickwall)	DV1	300	14.985	1.978.020
9	Tuğla Duvar (brickwall)	DV2	120	5.993	791.076
10	Tuğla Duvar (brickwall)	DV3	120	5.993	791.076
11	Tuğla Duvar (brickwall)	DV4	120	5.993	791.076
12	Tuğla Duvar (brickwall)	DV5	120	5.993	791.076
13	Kalıp (formwork)	KL1	300	14.985	1.978.020
14	Kalıp (formwork)	KL2	300	14.985	1.978.020
15	Kalıp (formwork)	KL3	120	5.993	791.076
16	Kalıp (formwork)	KL4	120	5.993	791.076
17	Kalıp (formwork)	KL5	120	5.993	791.076
18	Kalıp (formwork)	KL6	120	5.993	791.076
19	Kalıp (formwork)	KL7	120	5.993	791.076
20	Laminat Parke (laminatfloor)	PR1	300	14.985	1.978.020
21	Laminat Parke (laminatfloor)	PR2	300	14.985	1.978.020
22	Laminat Parke (laminatfloor)	PR3	120	5.993	791.076
23	Laminat Parke (laminatfloor)	PR4	120	5.993	791.076
24	Laminat Parke (laminatfloor)	PR5	120	5.993	791.076
25	Laminat Parke (laminatfloor)	PR6	120	5.993	791.076
26	Laminat Parke (laminatfloor)	PR7	120	5.993	791.076
27	Yer Seramik (ceramictile)	SR1	300	14.985	1.978.020
28	Yer Seramik (ceramictile)	SR2	300	14.985	1.978.020
29	Yer Seramik (ceramictile)	SR3	120	5.993	791.076
30	Yer Seramik (ceramictile)	SR4	120	5.993	791.076
31	Yer Seramik (ceramictile)	SR5	120	5.993	791.076
32	Yer Seramik (ceramictile)	SR6	120	5.993	791.076
33	Yer Seramik (ceramictile)	SR7	120	5.993	791.076
34	Alçı Sıva (plaster)	SV1	300	14.985	1.978.020
35	Alçı Sıva (plaster)	SV2	240	11.988	1.582.416
36	Alçı Sıva (plaster)	SV3	60	2.997	395.604
37	Alçı Sıva (plaster)	SV5	240	11.988	1.582.416
38	Alçı Sıva (plaster)	SV6	120	5.993	791.076
39	Alçı Sıva (plaster)	SV7	120	5.993	791.076

No	İş Aktivitesi	ID	Kayıt Süresi (sn)	Kayıt Adet (Satır)	Toplam Veri (Adet)
40	Alçı Sıva (plaster)	SV8	120	5.993	791.076
41	Alçı Sıva (plaster)	SV9	120	5.993	791.076
42	Alçı Sıva (plaster)	SV10	120	5.993	791.076
<b>Genel Toplam</b>			<b>6.952</b>	<b>347.623</b>	<b>45.886.236</b>

Tablodan görüldüğü üzere tez çalışması boyunca 6.952 saniye ( $\approx$  116 dakika) içinde toplam 45.886.236 adet veri kayıt altına alınmıştır.

### 3.4.2. Ses Verilerinin Toplanması

Ses data aktivitesi toplanması için iş aktivitesinin uygulandığı alanın 2 köşesinde aktivite yapan işçiye yaklaşık 2-3 metre uzaklıkta yer alan telefonların mikrofonları kullanılmıştır. Telefon mikrofonundan Sensorlog programı ile sesin şiddetinin dB cinsinden en yüksek ve ortalama değerleri kayıt altına alınmıştır. Bu süreçte 3.583 sn. 50 Hz frekansta kayıt yapılmış olup ses şiddetinin en yüksek ve ortalama değeri olmak üzere toplam 358.312 adet veri kayıt altına alınmıştır. Aktivite bazında sensorlog programı ile kayıt altına alınan verilerin özeti aşağıda gösterilmiştir.

Tablo 3.3: Sersorlog programı ses verilerinin iş bazında özeti

Aktivite Adı	Sensorlog Kayıt Süresi (sn)	Toplam Kayıt Adet (Satır)	Toplam Veri (Adet)
Alçı Sıva (plaster)	588	29.400	58.800
Boya (paint)	596	29.796	59.592
Kalıp (formwork)	592	29.602	59.204
Laminat Parke (laminatfloor)	600	29.982	59.964
Tuğla Duvar (brickwall)	612	30.604	61.208
Yer Seramik (ceramictile)	595	29.772	59.544
<b>Genel Toplam</b>	<b>3.583</b>	<b>179.156</b>	<b>358.312</b>

Bununla birlikte iş aktivitesi yapılan ortamdaki ses Iphone cep telefonu ile IOS içindeki yerleşik sesli notlar uygulaması ile kaydedilmiştir. Bu kayıta IOS sesli not uygulaması varsayılan ayar olarak sesi 48 kHz (48.000 Hz) frekansta ve .m4a formatında kaydetmektedir. İş aktivitesi bazında ortamdaki alınan ses kayıtlarına ilişkin özet aşağıda sunulmuştur.

Tablo 3.4: IOS sesli not programı ile kaydedilen verilerin iş bazında özeti

<b>Aktivite Adı</b>	<b>Ses Kayıt Süresi (sn)</b>	<b>Toplam Kayıt Adet (Satır)</b>	<b>Toplam Veri (Adet)</b>
Alçı Sıva (plaster)	584	28.032.000	28.032.000
Boya (paint)	571	27.408.000	27.408.000
Kalıp (formwork)	587	28.176.000	28.176.000
Laminat Parke (laminatfloor)	584	28.032.000	28.032.000
Tuğla Duvar (brickwall)	598	28.704.000	28.704.000
Yer Seramik (ceramictile)	608	29.184.000	29.184.000
<b>Genel Toplam</b>	<b>3.532</b>	<b>169.536.000</b>	<b>169.536.000</b>

### 3.5. VERİ AKTARIM, ETİKETLEME VE ÖN İŞLEME SÜRECİ

Bu bölümde yukarıda toplanan ham sensör ve ses verilerinin bilgisayara ve derin öğrenme ağına aktarılması öncesinde yapılan veri ön işleme süreci anlatılmıştır. Esasen derin öğrenmenin, makine öğrenmesine göre en büyük avantajlarından birisi, öznelik çıkarımının (Feature extraction) algoritmalar tarafından yapılması nedeniyle daha az veri ön işleme gerektirmesidir. Tez çalışmasında da LSTM derin öğrenme ağı kullanılması sebebiyle veri ön işleme daha çok verinin ilk ve son kısmındaki verinin temizlenmesi ile verinin LSTM ağına aktarılması için ön hazırlık safhasını içermektedir. Ayrıca ön işleme sonrası gözetimli öğrenmenin (supervised learning) adımlarından biri olan bu verilerin hangi aktiviteye ait olduğunun tanımlanması amacıyla etiketleme işlemi gerçekleştirilmiştir.

Literatürde yapılan çalışmalar çoğunlukla ivme sensörü verileri kullanılarak yapılmış olup vücut pozisyonu ile hareket belirlenmesi üzerine hiçbir çalışma bulunamamıştır. Bu tez çalışmasında kapsamında sensörden gelen ivme verileri yanında, sadece vücut konumları kullanılarak hareket tahmini ile ivme ve vücut konumu ile tahminde kullanılmıştır.

Böylece tez çalışmada Sensör verilerinden 3 farklı çalışma yapılmıştır.

- İvme Sensörü Verileri (ACC) : Bu aşamada seçilen iş gruplarında ağırlıklı olarak ellerin kullanılması nedeniyle sağ el ve sol el ivme verileri ile aktivite tahmini
- Vücut Pozisyon Verileri (POS) : Bu aşamada sensör ile elde edilen baş, sağ el, sol el, sağ ayak pozisyon verileri kullanılmıştır.

- İvme ve Pozisyon Verileri Kombinasyonu (ACCPOS) : Bu aşamada yukarıdaki her iki veri seti birleştirilerek aktivite tahmini yapılmıştır.

Ses verilerinde ise böyle bir grupta yapılmamıştır. Ses verileri temizleme ve derin öğrenme ağına hazırlık için ön işleme sonrası direkt kullanılmıştır.

### 3.5.1. Sensör Verileri Aktarım ve Ön İşleme

Toplanan her bir sensör konumuna ait ham veriler Notch Pioneer yazılımı ile .csv formatında bilgisayara aktarılmıştır. Tez çalışması kapsamında seçilen iş aktiviteleri incelendiğinde iş aktivitesi sırasında hareket tespitine etki eden ana sensör noktalarının el ve bacak hareketleri olduğu tespit edilmiştir.

İlk olarak Sensör verilerinden sadece ivme sensörünün kullanıldığı ilk çalışmada sağ ve solden gelen veriler kullanılmıştır.

İkinci olarak pozisyon verilerinin kullanıldığı çalışmada yerde yapılan ve ayakta çalışılan iş aktivite tahminine katkı sağlaması açısından baş, sağ el, sol el, sağ ayak pozisyon verileri kullanılmıştır.

Üçüncü olarak, ilk ve ikinci çalışmada kullanılan ivme sensörü ve pozisyon verileri birleştirilerek kullanılmıştır.

Aşağıda boya aktivitesi için sensör verilerinin aktarımının gösterildiği kodlar yer almaktadır.

```
%Global Right Arm
glbrfaBY2=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
LSTM\RawDATA\BY2\Global_SensorData_RightForeArm.csv');
glbrfaBY2=glbrfaBY2(:,2:7);
%Local Right Arm
lclrfaBY2=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
LSTM\RawDATA\BY2\Local_SensorData_RightForeArm.csv');
lclrfaBY2=lclrfaBY2(:,2:7);
%Positions Right Arm
posrfaBY2=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
LSTM\RawDATA\BY2\Positions_RightForeArm.csv');
posrfaBY2=posrfaBY2(:,2:4);
%Global Left Arm
glblfaBY2=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
LSTM\RawDATA\BY2\Global_SensorData_LeftForeArm.csv');
```

```

glblfaBY2=glblfaBY2(:,2:7);
%Local Left Arm
lcllfaBY2=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
LSTM\RawDATA\BY2\Local_SensorData_LeftForeArm.csv');
lcllfaBY2=lcllfaBY2(:,2:7);
%Positions Left Arm
poslfaBY2=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
LSTM\RawDATA\BY2\Positions_LeftForeArm.csv');
poslfaBY2=poslfaBY2(:,2:4);
%Positions Head
posheadBY2=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
LSTM\RawDATA\BY2\Positions_Head.csv');
posheadBY2=posheadBY2(:,2:4);
%Positions Right Leg
posrlgBY2=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
LSTM\RawDATA\BY2\Positions_RightLowerLeg.csv');
posrlgBY2=posrlgBY2(:,2:4);

```

Sonrasında aktarılan bu veriler hangi aktiviteye ait olduğunu gösterilmesi amacıyla etiketlenmiştir. Aşağıda verinin etiketlenmesi için kullanılan kodlar yer almaktadır. Bu örnekte boya aktivitesine ait veriler “paint” olarak etiketlenmiştir.

```

%Categorical Work Desc
[m,n] = size(glbrfaBY2);
%Work=zeros(m,1)
wrkcatBY2=categorical(repmat("paint",[m 1]));

```

Sonraki süreçte her bir sensöre ait aktarılan ve etiketlenen veriler birleştirilmiştir. Toplanan sensör verilerinde sistem olarak ilk hazırlık durumu safhasından iş ekipmanını alarak işe başlama safhasına kadar yaklaşık 3-5 sn. arası bir süre geçmektedir. 50 Hz kayıt frekansı dikkate alındığında bu yaklaşık 150-250 arası kayıta karşılık gelmektedir. Bu nedenle veri kirliliğine yol açmaması için işin başlangıcında yer alan bu veriler silinmiştir.

Sonrasında ise veri farklı durumlarda tahmin doğruluk oranını artırmak amacıyla 6 sn. lik 300 kayıttan oluşan gruplara ayrılmış ve derin öğrenme ağında eğitim işlenmeye hazır duruma getirilmiştir. Bu işlemler sensör verilerinden yapılacak her üç çalışma içinde gerçekleştirilmiştir.

```

%Combine All
BY2all=table(glbrfaBY2,lclrfaBY2,glblfaBY2,lcllfaBY2,posrfaBY2,poslfaBY2,poseadBY2,posrlgBY2,wrkcatBY2);

%Clear Starting
BY2all(1:287,:)=[];
T1acc=[BY2all.glbrfaBY2,BY2all.lclrfaBY2 ,BY2all.glblfaBY2,BY2all.lcllfaBY2];
T2accpos=[BY2all.glbrfaBY2,BY2all.posrfaBY2
,BY2all.glblfaBY2,BY2all.poslfaBY2];
T3pos=[BY2all.posrfaBY2,BY2all.poslfaBY2
,BY2all.poseadBY2,BY2all.posrlgBY2];
CatBY2=[BY2all.wrkcatBY2];
[r,c] = size(T1acc);
t=r/300
rowDist = [300 300 300 300 300 300 300 300 300 300 300 300 300 300 300 300 300 300
300 300 300 300 300 300 300 300 300 300 300 300 300 300 300 300 300 300 300
300 300 300];

%ACC Train data
T1BY2acc=mat2cell(T1acc,rowDist);
T1BY2acc=cellfun(@transpose,T1BY2acc,"UniformOutput",false);
TRCatBY2acc=mat2cell(CatBY2,rowDist);
TRCatBY2acc=cellfun(@transpose,TRCatBY2acc,"UniformOutput",false);

%ACCPOS Train data
T2BY2accpos=mat2cell(T2accpos,rowDist);
T2BY2accpos=cellfun(@transpose,T2BY2accpos,"UniformOutput",false);
%POS Train data
T3BY2pos=mat2cell(T3pos,rowDist);
T3BY2pos=cellfun(@transpose,T3BY2pos,"UniformOutput",false);
save("TrainData.mat","T1BY2acc","T2BY2accpos","T3BY2pos","TRCatBY2acc","-
append')

```

En son olarak toplanan verilerin içinden rastgele 24 sn.lik 1200 adet kayıt test verisi olarak ayrılmıştır. Test datası olarak rastgele seçilen bu veriler eğitim setinin içinden çıkarılmıştır.

Sensör verilerinden elde edilen iş aktivitelerinden test verisi olarak ayrılan kısmı iş grubu bazında aşağıda gösterilmiştir.



Tablo 3.5: Sensör test verileri iş bazında özet bilgileri

İş Aktivite Tanımı	Test Kayıt Sayısı	Test Kayıt Süresi (sn)
Alçı Sıva (plaster)	2.100	42
Boya (paint)	2.100	42
Kalıp (formwork)	2.100	42
Laminat Parke (laminatfloor)	2.100	42
Tuğla Duvar (brickwall)	2.100	42
Yer Seramik (ceramictile)	2.100	42
<b>Genel Toplam</b>	<b>12.600</b>	<b>252</b>

### 3.5.2. Ses Verileri Aktarım ve Ön İşleme

Ses kayıtları 2 farklı şekilde toplanmıştır. Bu veri toplama metodu yukarıda anlatılmış olup bu bölümde toplanan verilerin nasıl işlenerek eğitim için hazır hale getirildiği anlatılmıştır.

Ses kayıtlarının ilk şekli olan sensorlog programı ile 50 Hz frekansında kayıt altına alınan verilerde yine sensör verilerine benzer şekilde Matlab Programı ile aşağıdaki kodlar kullanılarak aktarılmıştır. Ancak ses verilerinde kayıt aktivite başladıktan sonra yapılması sebebiyle başlangıç aşamasında temizlenmesi gerekli veri yer almamaktadır. Bu sebeple veri temizle işlemine tabii tutulmamış sadece veriler aktarılarak etiketlenmiş ve 6 sn.lik 300 adet kayıtlı gruplara ayrılmıştır. Sıva aktivitesine ilişkin örnek Veri aktarımı, gruplanması ve etiketlenmesine ilişkin kodlar aşağıda yer almaktadır.

#### % Kayıt İçin Train ve Test Data Hazırlama

```
SV3=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
Sound\SoundSensorLOG\SV3.csv','Delimenter','');
SV3=SV3(:,5:6);
len=length(SV3);
SV3=SV3(20:end-(len-5719),:);
len=length(SV3);
rowDist = [300 300 300 300 300 300 300 300 300 300 300 300 300 300 300 300 300 300
300 300];
SV3tr=mat2cell(SV3,rowDist);
SV3tr=cellfun(@transpose,SV3tr,"UniformOutput",false);
%
SVcatsq=categorical(repmat("plaster",[len 1]));
SVcatsq=mat2cell(SVcatsq,rowDist);
SVcatsq=cellfun(@transpose,SVcatsq,"UniformOutput",false);
SVcat=categorical(repmat("plaster",[19 1]));
```

```

%
SV4=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
Sound\SoundSensorLOG\SV4.csv','Delimiter','');
SV4=SV4(:,5:6);
len=length(SV4);
SV4=SV4(100:end-(len-5799),:);
len=length(SV4);
%
SV4tr=mat2cell(SV4,rowDist);
SV4tr=cellfun(@transpose,SV4tr,"UniformOutput",false);
%
SV5=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
Sound\SoundSensorLOG\SV5.csv','Delimiter','');
SV5=SV5(:,5:6);
len=length(SV5);
SV5=SV5(94:end-(len-5793),:);
len=length(SV5);
%
SV5tr=mat2cell(SV5,rowDist);
SV5tr=cellfun(@transpose,SV5tr,"UniformOutput",false);
%
SV6=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
Sound\SoundSensorLOG\SV6.csv','Delimiter','');
SV6=SV6(:,5:6);
len=length(SV6);
SV6=SV6(84:end-(len-5783),:);
len=length(SV6);
%
SV6tr=mat2cell(SV6,rowDist);
SV6tr=cellfun(@transpose,SV6tr,"UniformOutput",false);
%
SV7=readmatrix('C:\Users\user\MATLAB Drive\PhdTEZ
Sound\SoundSensorLOG\SV7.csv','Delimiter','');
SV7=SV7(:,5:6);
len=length(SV7);
SV7=SV7(100:end-(len-5799),:);
len=length(SV7);
%
SV7tr=mat2cell(SV7,rowDist);
SV7tr=cellfun(@transpose,SV7tr,"UniformOutput",false);
%
SVTR=[SV3tr;SV4tr;SV5tr;SV6tr;SV7tr]
SVCATSQ= repmat(SVcatsq,5,1)
SVCAT= repmat(SVcat,5,1)

```

Sonrasında yine benzer şekilde her bir iş aktivitesi verileri içinden rastgele test verileri ayrılmıştır. Ses verilerinden elde edilen iş aktivitelerinden test verisi olarak ayrılan kısmı iş grubu bazında aşağıda gösterilmiştir.

Tablo 3.6: Ses test verilerinin iş bazında özet bilgileri

İş Aktivite Tanımı	Test Kayıt Sayısı	Test Kayıt Süresi (sn)
Alçı Sıva (plaster)	1.200	24
Boya (paint)	1.200	24
Kalıp (formwork)	1.200	24
Laminat Parke (laminatfloor)	1.200	24
Tuğla Duvar (brickwall)	1.200	24
Yer Seramik (ceramictile)	1.200	24
<b>Genel Toplam</b>	<b>7.200</b>	<b>124</b>

İkinci ses kayıt yöntemi olarak telefon mikrofonundan iş sırasında aktivite sesleri kaydedilmiştir. Kaydedilen bu sesler Matlab yazılımı ile önce sayısal veriye dönüştürülmüştür. Aşağıda 2 dakikalık bir kayıt için .m4a ses dosyasının audioread komutu ile veriye dönüştürme aşaması gösterilmiştir.

```
[DV3,Fs]=audioread('C:\Users\user\MATLAB Drive\PhdTEZ
Sound\SoundDataIphone\DV3.m4a');
len=length(DV3);
DV3=DV3(len-(110*Fs):end-1,:);
dist=Fs*10
len=length(DV3)
rowDist = [dist dist dist dist dist dist dist dist dist dist];
DV3tr=mat2cell(DV3,rowDist);
DV3tr=cellfun(@transpose,DV3tr,"UniformOutput",false);

DVcatsq=categorical(repmat("brickwall",[len 1]));
DVcatsq=mat2cell(DVcatsq,rowDist);
DVcatsq=cellfun(@transpose,DVcatsq,"UniformOutput",false);
DVcat=categorical(repmat("brickwall",[11 1]));
```

Ancak bu .m4a formatında ses kaydı 48.000 hZ frekasında olması nedeniyle 2 dakikalık ses kaydı ile 5.760.000 adet veri oluşmuştur. Proje toplamı dikkate alındığında bu sayı 169.536.000 adet veriye tekabül etmektedir. Bu kadar veri ile işlemeyen derin öğrenme ağı ile eğitim denenmiş ancak bilgisayar sistem kaynaklarının yeterli olmaması nedeniyle hata ile karşılaşmıştır. Bu nedenle 48.000 hZ verinin 48 hZ olarak indirgenmesi için bir algoritma geliştirilmiştir. Bu algoritma ile 1 sn için olan 48.000 adet olan verinin 10.000 adetli gruplar halinde o grup içindeki en yüksek (max), en düşük (min) ve ortalama (mean) hesaplanarak kayıt

tekrar düzenlenmiştir. Bu veri hazırlama yöntemi ile 48.000 Hz olan ses verisi işlenerek 4,8 Hz olarak indirgenmiştir. İndirgenen bu veri her 10.000 kayıt içindeki en yüksek, en düşük ve ortalama verilerden oluşmaktadır. Bu yapılan indirgeme işlemine ilişkin kodlar aşağıda gösterilmiştir.

```
function y=omur(x)
l=length(x)
    parfor i= 1:l/10
        %b=max(x(:,2*i-1),x(:,2*i))
        b=max(x(:,10*i-9:10*i))
        y(:,i) = b;
        %ort=(sqrtm((x(:,2*i-1))^2)+sqrtm((x(:,2*i))^2))/2
        %orti(:,i) = ort;
        %k=min(x(:,2*i-1),x(:,2*i))
        %mini(:,i) = k;
    end

    parfor i= 1:l/10
        %b=max(x(:,2*i-1),x(:,2*i))
        %y(:,i) = b;
        ort=mean(x(:,10*i-9:10*i))
        y(:,i) = ort;
        %k=min(x(:,2*i-1),x(:,2*i))
        %y(:,i) = k;
    end

    end
    %y=[maxi;orti;mini]
    %y=[maxi;orti;mini]
end
function y=omur(x)
l=length(x)
    parfor i= 1:l/10
        %b=max(x(:,2*i-1),x(:,2*i))
        %y(:,i) = b;
        %ort=(sqrtm((x(:,2*i-1))^2)+sqrtm((x(:,2*i))^2))/2
        %orti(:,i) = ort;
        k=min(x(:,10*i-9:10*i))
        y(:,i) = k;
    end

    end
    %y=[maxi;orti;mini]
    %y=[maxi;orti;mini]
XTrainMax4=cellfun(@omurmax,XTrainDataIPTall,"UniformOutput",false);
XTrainMin4=cellfun(@omurmin,XTrainDataIPTall,"UniformOutput",false);
XTrainOrt4=cellfun(@omurort,XTrainDataIPTall,"UniformOutput",false);

XTmax4=gather(XTrainMax4)
XTmin4=gather(XTrainMin4)
XTort4=gather(XTrainOrt4)
m=length(XTmax4)
```

```
parfor i=1:m
    a=cell2mat(XTmax4(i,:))
    b=cell2mat(XTmin4(i,:))
    c=cell2mat(XTort4(i,:))
    k=[a;b;c]
    XTrain{i,:} = k;
end
```

Bu işlemler sonrası hem sensör hem ses verileri derin öğrenme ağına aktarmak için hazır duruma gelmiştir.

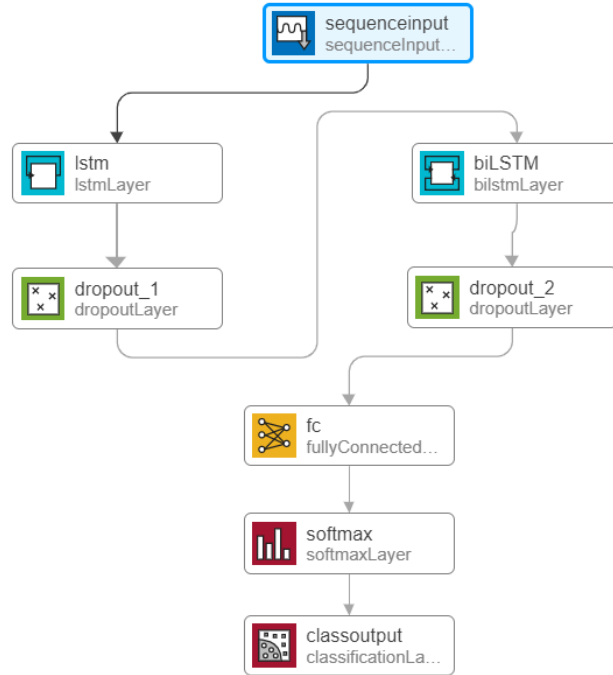


#### 4. BULGULAR

Bir önceki bölümde veri toplama süreci ve toplanan verilerin derin öğrenme ağında kullanımına yönelik ön işleme süreci anlatılmıştır. Bu aşamada veriler derin öğrenme ağında eğitime hazır şekle getirilmiş ayrıca test ve eğitim verileride hazırlanmıştır. Bu çalışmada gerek ses gerek sensör verilerinin bir zaman serisi verisi olması nedeniyle LSTM ağı kullanılmıştır. Böylece makine öğrenmesinin adımlarından olan veri işleme sürecinde özellik çıkarımına (feature extraction) LSTM derin öğrenme ağı kullanılması nedeniyle gerek duyulmamaktadır. Bu nedenle yukarıda hazırlanan veriler direkt derin öğrenme ağına aktarılmıştır.

Çalışmanın başlangıcında sadece LSTM ağı kullanılmış olup ilk başlarda %86 civarında olan doğruluk oranının artırılması amacıyla, hiperparametrelerin optimizasyonu yanında ağa BiLSTM katmanı eklenerek daha derin bir ağ oluşturulmuştur. Bu süreç sonunda en başarılı sonucun elde edildiği çalışmada kullanılan ağ aşağıda sunulmuştur. Zaman serisi verisi LSTM ağına izlediği akışta başarıyı etkileyen en önemli faktörlerden biri en iyi sonuca ulaştıracak hiperparametrelerin belirlenmesidir.

Şekil 4.1: Tez kapsamında oluşturulan derin öğrenme ağı şematik görüntüsü



Doktora tezi sırasında eğitimde kullanılacak toplam devir sayısı (Epoch), LSTM ve BiLSTM Layer kaç katmandan oluşacağı ve eğitim sırasında düşürülecek nöronların (dropout layer) verinin yüzde oranı gibi hiperparametlerin optimizasyonu amacı ile bir algoritma kullanılmıştır. Bu yöntemle öncelikli olarak daha geniş aralıkta bir parametre bandı kullanılmış sonrasında ile en iyi sonuca ulaşan parametre aralığında daha yakın parametreler kullanılmıştır. Böylelikle geniş bir aralıkta parametrelerin eğitim sonucuna etkisi gözlemlenmiştir. Oluşturulan algoritma ile aynı anda 6 adet farklı parametre ile, eğitim için kullanılan bilgisayarda yer alan 6 çekirdekli işlemcinin her bir işlemcisi paralel olarak eğitim sürecini tamamlamıştır. Böylece tek bir parametre seti ile geçen eğitim sürecinde toplam 6 adet farklı parametre ile oluşan sonuçlar değerlendirilerek zaman ve eğitim sonucu kalitesine katkıda bulunmaktadır.

```

ParWork=input('Par Eğitim Sayisi Kac Adet?');
f = figure;
f.Visible = true;
for i=1:ParWork
    subplot(2,ParWork/2,i)
    xlabel('Iteration');
    ylabel('Training accuracy');
    lines(i) = animatedline;
end
D = parallel.pool.DataQueue;
afterEach(D, @(opts) updatePlot(lines, opts{:}));

```

#### 4.1. SENSÖR VERİLERİ DERİN ÖĞRENME AĞI EĞİTİM

Yukarıda veri toplama ve işleme bölümünde anlatıldığı üzere toplanan sensör verileri 3 farklı gruba ayrılmıştır. Bir tanesinde sadece sağ ve sol el ivme sensörü verileri, ikincisinde ellere sağ ayak ve baş verileri eklenerek bunların pozisyon verileri kullanılmıştır. Son olarak ise bu iki veri seti birleştirilerek aktivite tahmini yapılmıştır. Buradaki amaç literatürde ağırlıklı olarak kullanılan ivme sensörü verilerine, ilgili organın pozisyon verilerinde eklenerek ve sonrasında hem ivme sensörü hemde pozisyon verileri kullanılarak oluşturulan derin öğrenme ağındaki sonuçların ve etkinliğinin karşılaştırılması hedeflenmiştir.

#### 4.1.1. Sensör İvme Verileri ile Aktivite Tanımlama (ACC)

Çalışmanın bu bölümünde eğitim için sensörden elde edilen veriler 6 sn. lik ( $6 \times 50 = 300$  adet veri) gruplara ayrılarak 1097 adet grup kategorize edilmiştir. Çalışmada sensörden elde edilen pozisyon verileri hariç tüm veriler kullanılmıştır. XYZ ekseninde tüm verileri içeren çalışmada eğitim için  $24 \times 300 \times 1097 = 7.898.400$  adet veri kullanılmıştır. Yine her bir iş kalemi için yine 300 adet gruplar halinde test grupları oluşturulmuştur. Test verileri eğitim setinde kullanılmamıştır ve bu veriler eğitilmiş ağın ilk defa göreceği veriler olup derin öğrenme ağının doğruluğunun gerçek anlamda anlaşılması açısından önemli bir durum oluşturmaktadır. Araştırmada kullanılan 6 adet iş grubunun her birine ait 42 sn. lik test verisi kullanılmıştır. Bu noktadan hareketle testte  $6 \times 42 \times 50 \times 24 = 302.400$  adet veri kullanılmıştır. Araştırmada herbir iş için kullanılan bu veriler etiketlenerek eğitim ağına aktarılmıştır.

Sonrasında bu veriler yukarıda anlatmış olduğumuz eğitim ağına aktarılmıştır. Bu çalışmada derin öğrenme ağında farklı katmanlarda bir adet LSM ve bir adet BiLSTM layer ve 2 adet dropout layer kullanılmıştır. Bu arada en etkin sonucu almak için öncelikle 6 farklı parametre kullanılarak eğitim sonuçları değerlendirilmiştir. Bu parametreler aşağıdaki tabloda gösterilmiştir.

Tablo 4.1: Sensör verileri için kullanılan hiperparametre setlerine ait değerler

Eğitim Parametre	Set 1	Set 2	Set 3	Set 4	Set 5	Set 6
MaxEpochs	33	30	30	25	20	20
LayerLstm	66	66	99	99	100	120
LayerBilstm	33	33	33	33	50	50
dropoutL1	0,33	0,20	0,33	0,20	0,20	0,20
dropoutL2	0,33	0,20	0,33	0,20	0,20	0,20

Yukarıdaki parametreler ile eğitim ağına ait sonuçları incelediğimizde;

Set 1 için eğitim süresi 00:08:27 olup, % 99,98 Eğitim doğruluk ve %100 test doğruluk oranına ulaşmıştır. Set 1 parametreleri test doğruluk oranı %100 ü bulan tek parametre setidir. Eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.



**Training 1 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
	<b>Target Class</b>							

Şekil 4.2: Hiperparametre Set1 için hata matrisi görüntüsü

Set 2 için eğitim süresi 00:07:49 olup, % 99,99 Eğitim doğruluk ve %98,79 test doğruluk oranına ulaşmıştır. Set 2 eğitimi en kısa sürede tamamlamıştır. Burada sadece test verilerinde tuğla duvar ve seramik işinden küçük bir kısmını yanlış tahminlemiştir. Set 2 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 2 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	142 1.1%	0 0.0%	0 0.0%	0 0.0%	93.7% 6.3%
	brickwall	0 0.0%	0 0.0%	1958 15.5%	11 0.1%	0 0.0%	0 0.0%	99.4% 0.6%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2089 16.6%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	93.2% 6.8%	99.5% 0.5%	100% 0.0%	100% 0.0%	98.8% 1.2%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
<b>Target Class</b>								

Şekil 4.3: Hiperparametre Set2 için hata matrisi görüntüsü

Set 3 için eğitim süresi 00:09:13 olup, % 99,95 Eğitim doğruluk ve %99,52 test doğruluk oranına ulaşmıştır. Bu eğitim setinde sadece tuğla duvar işinin küçük bir kısmını kalıp işçiliği olarak tahminlemiştir. Set 3 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 3 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	61 0.5%	0 0.0%	0 0.0%	0 0.0%	97.2% 2.8%
	brickwall	0 0.0%	0 0.0%	2039 16.2%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	97.1% 2.9%	100% 0.0%	100% 0.0%	100% 0.0%	99.5% 0.5%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
<b>Target Class</b>								

Şekil 4.4: Hiperparametre Set3 için hata matrisi görüntüsü

Set 4 için eğitim süresi 00:08:06 olup, % 99,50 Eğitim doğruluk ve %99,00 test doğruluk oranına ulaşmıştır. Bu eğitim setinde sadece tuğla duvar ve kalıp işini yanlış olarak tahminlemiştir. Set 4 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 4 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2098 16.7%	124 1.0%	0 0.0%	0 0.0%	0 0.0%	94.4% 5.6%
	brickwall	0 0.0%	0 0.0%	1976 15.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	2 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	99.9% 0.1%
		100% 0.0%	99.9% 0.1%	94.1% 5.9%	100% 0.0%	100% 0.0%	100% 0.0%	99.0% 1.0%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
<b>Target Class</b>								

Şekil 4.5: Hiperparametre Set4 için hata matrisi görüntüsü

Set 5 için eğitim süresi 00:07:51 olup, % 99,99 Eğitim doğruluk ve %97,78 test doğruluk oranına ulaşmıştır. Set 5 en düşük test doğruluk oranına sahip parametre setidir. Bu eğitim setinde sadece tuğla duvar işi, kalıp işi olarak yanlış tahminlenmiştir. Set 5 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 5 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	280 2.2%	0 0.0%	0 0.0%	0 0.0%	88.2% 11.8%
	brickwall	0 0.0%	0 0.0%	1820 14.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	86.7% 13.3%	100% 0.0%	100% 0.0%	100% 0.0%	97.8% 2.2%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
	<b>Target Class</b>							

Şekil 4.6: Hiperparametre Set5 için hata matrisi görüntüsü


Set 6 için eğitim süresi 00:09:29 olup, % 100 Eğitim doğruluk ve %99,23 test doğruluk oranına ulaşmıştır. Eğitim süresi en uzun süren ve en yüksek eğitim doğruluk oranına sahip parametre setidir. Bu eğitim setinde de sadece tuğla duvar işi, kalıp işi olarak yanlış tahminlenmiştir. Set 6 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 6 Confusion Matrix**

<b>Output Class</b>	paint	<b>2100</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	formwork	<b>0</b> 0.0%	<b>2100</b> 16.7%	<b>97</b> 0.8%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>95.6%</b> 4.4%
	brickwall	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>2003</b> 15.9%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	ceramictile	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>2100</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	laminatelfloor	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>2100</b> 16.7%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	plaster	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>2100</b> 16.7%	<b>100%</b> 0.0%
		<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>95.4%</b> 4.6%	<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>99.2%</b> 0.8%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
<b>Target Class</b>								

Şekil 4.7: Hiperparametre Set6 için hata matrisi görüntüsü

Her bir sete ilişkin eğitim süreci doğruluk grafiği aşağıda sunulmuştur.



Şekil 4.8: Her bir parametre setine ait eğitim doğruluk oranı grafiği

Eğitim sonrası sonuçlara ilişkin özet tablo aşağıda sunulmuştur.

Tablo 4.2: Eğitim parametre setleri sonuç özeti

Eğitim Parametre		Set 1	Set 2	Set 3	Set 4	Set 5	Set 6
Parametreler	MaxEpochs	33	30	30	25	20	20
	LayerLstm	66	66	99	99	100	120
	LayerBilstm	33	33	33	33	50	50
	dropoutL1	0,33	0,20	0,33	0,20	0,20	0,20
	dropoutL2	0,33	0,20	0,33	0,20	0,20	0,20
Sonuçlar	Eğitim Süresi	00:08:27	<b>00:07:49</b>	00:09:13	00:08:06	00:07:51	00:09:29
	Train Accuracy	99.98%	99.99%	99.95%	99.50%	99.99%	<b>100.00%</b>
	Test Accuracy	<b>100.00%</b>	98.79%	99.52%	99.00%	97.78%	99.23%


Tablo incelendiğinde eğitim süresi 8-10 dk. arasında değişmekte iken eğitim doğruluğu en düşük % 99,50 olduğu gözlemlenmiştir. Eğitim setinin daha önce hiç görmediği test verilerinde ise doğruluk oranı en düşük % 97,78 olmasına karşın %100 doğruluk oranı da yakalanmıştır. Eğitim doğruluk ortalaması % 99,90 iken test doğruluk oranı ortalaması %99,05 olarak

hesaplanmıştır. Her sette yanlış tahmin edilen veriler incelendiğinde bunların ağırlıklı olarak tuğla duvar işinin küçük bir kısmının kalıp işi olarak tahminlendiği görülmektedir.

Sonraki adımda yukarıdaki verilerin ışığında aşağıda belirtilen parametrelerle bir eğitim daha gerçekleştirilmiştir.

```
MaxEpochs = 27;
numHiddenUnits1 = 66;
numHiddenUnits2 = 33;
dropoutL1 = 0.33;
dropoutL2 = 0.33;
```

Bu nihai karar verilen parametreler ile eğitim 5 dakika 21 saniyede tamamlanmıştır. Eğitimde % 99,68 doğruluk oranına ulaşılırken test verilerinde % 100 doğruluk oranına ulaşılmıştır.



Şekil 4.9: İvme sensör verileri derin öğrenme ağı nihai eğitim ekran görüntüsü



**Confusion Matrix**

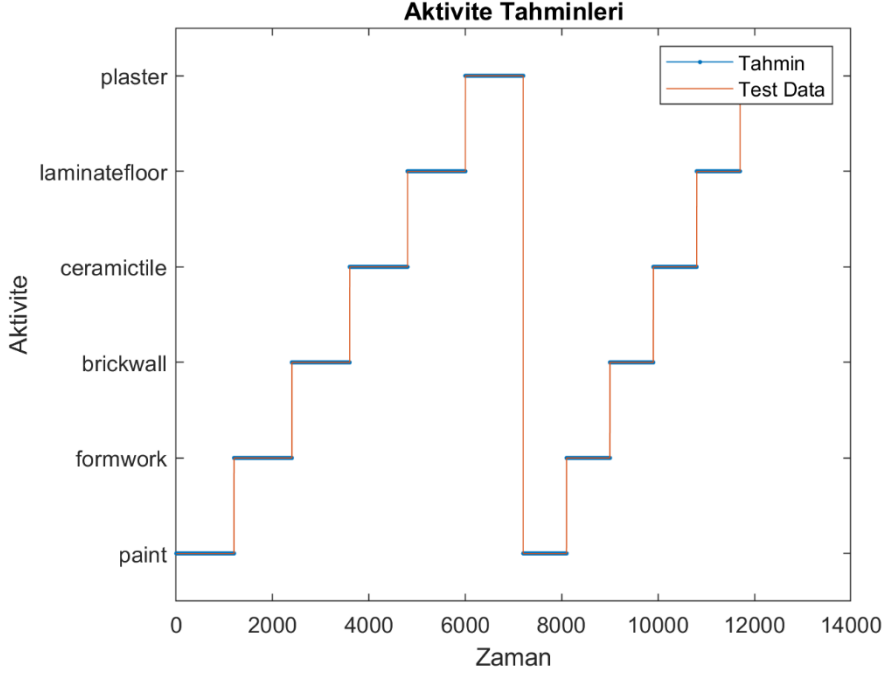
<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatetfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	formwork	brickwall	ceramictile	laminatetfloor	plaster		
	<b>Target Class</b>							

Şekil 4.10: İvme sensörü verileri nihai eğitim hata matrisi ekran görüntüsü

Görüldüğü üzere eğitim sonucunda 252 sn. 12600 adet verinin tümü doğru olarak tahmin edilmiştir.

Tablo 4.3: Toplam test verisi ve tahmin değerleri çıktısı

	FarkTabloR	FarkTabloN
1	"Toplam Test Veri"	12600
2	"Toplam Test Sure"	252
3	"Dogru Tahmin Veri"	12600
4	"Dogru Tahmin Sure"	252
5	"Yanlis Tahmin Veri"	0
6	"Yanlis Tahmin Sure"	0



Şekil 4.11: Test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik

Sonraki aşamada aşağıdaki kod ile tahminlerin yüzde oranı incelenmiştir.

```
WF=table(YTest1x',YPred1x',scr1(1,:)',scr1(2,:)',scr1(3,:)',scr1(4,:)',scr1(5,
:)',scr1(6,:)',...
'VariableNames',{'Test','Pred','Paint','Form','Brick','Ceramic','Laminate','Pl
aster'})
statarray = grpstats(WF,{'Pred'},{'min','max','mean'},...
'DataVars',{'Paint','Form','Brick','Ceramic','Laminate','Plaster'})
```

Tablo 4.4: İş bazında test verileri tahmin oranlarını gösterir tablo

Test	Pred	Paint	Form	Brick	Ceramic	Laminate	Plaster
paint	paint	0.7305	0.0207	0.0609	0.0529	0.0373	0.0977
paint	paint	0.7668	0.0187	0.0530	0.0445	0.0302	0.0868
paint	paint	0.8103	0.0162	0.0435	0.0339	0.0234	0.0727
paint	paint	0.8587	0.0134	0.0330	0.0228	0.0167	0.0553
paint	paint	0.9069	0.0104	0.0225	0.0132	0.0106	0.0364
paint	paint	0.9457	0.0076	0.0137	0.0065	0.0058	0.0207
paint	paint	0.9702	0.0053	0.0078	0.0029	0.0030	0.0108
paint	paint	0.9834	0.0037	0.0045	0.0013	0.0015	0.0056
paint	paint	0.9904	0.0025	0.0027	0.0006	0.0008	0.0030
paint	paint	0.9941	0.0017	0.0018	0.0003	0.0004	0.0017
paint	paint	0.9961	0.0011	0.0013	0.0002	0.0002	0.0010

Tablo 4.5: İş bazında tahminlerin yüzdesel dağılım özeti

Work	Min	Max	Ortalama
paint	72,40%	99,92%	99,38%
formwork	<b>91,89%</b>	<b>99,98%</b>	99,70%
brickwall	82,31%	99,95%	98,93%
ceramictile	62,87%	99,96%	99,10%
laminatelfloor	87,92%	99,97%	99,62%
plaster	91,30%	99,97%	<b>99,77%</b>

Sonuçlara göre en düşük yani en kötü doğruluk tahmini % 62,87 ile seramik işinde görülmüştür. Toplamda 6 adet iş aktivitesi ile bu çalışmanın yapıldığı düşünüldüğünde en kötü sonucun bile aslında ne kadar başarılı bir tahmin olduğu görülmektedir. En başarılı tahmin ise % 99,97 ortalama ile sıva işinde olmuştur. Sıva işinde en düşük tahmin oranı % 91,30 olarak gerçekleşmiştir.

Sonrasında test verisi kullanılarak çalışan ustanın hangi işte ne kadar süre çalıştığı aşağıdaki kod ile hesaplanmıştır.

```
WorkFreqTable=table(YPred1x(:));
WorkFreq = groupsummary(WorkFreqTable, "Var1");
WorkFreq.WorkTime = WorkFreq.GroupCount/50
```

Tablo 4.6: İşçinin hangi işi ne kadar süre ile yaptığını gösterir program çıktısı

	Var1	GroupCount	WorkTime
1	paint	2100	42
2	formwork	2100	42
3	brickwall	2100	42
4	ceramictile	2100	42
5	laminatelfloor	2100	42
6	plaster	2100	42

Sonuç olarak sadece sağ el ve sol el ivme sensörü verileri kullanılarak, oluşturulan derin öğrenme ağı ve parametreler ile, bir ustanın çalıştığı toplam 252 sn. süre içinde hangi işleri ne kadar süre ile yaptığı %100 doğruluk oranı ile tahmin edilmiştir.

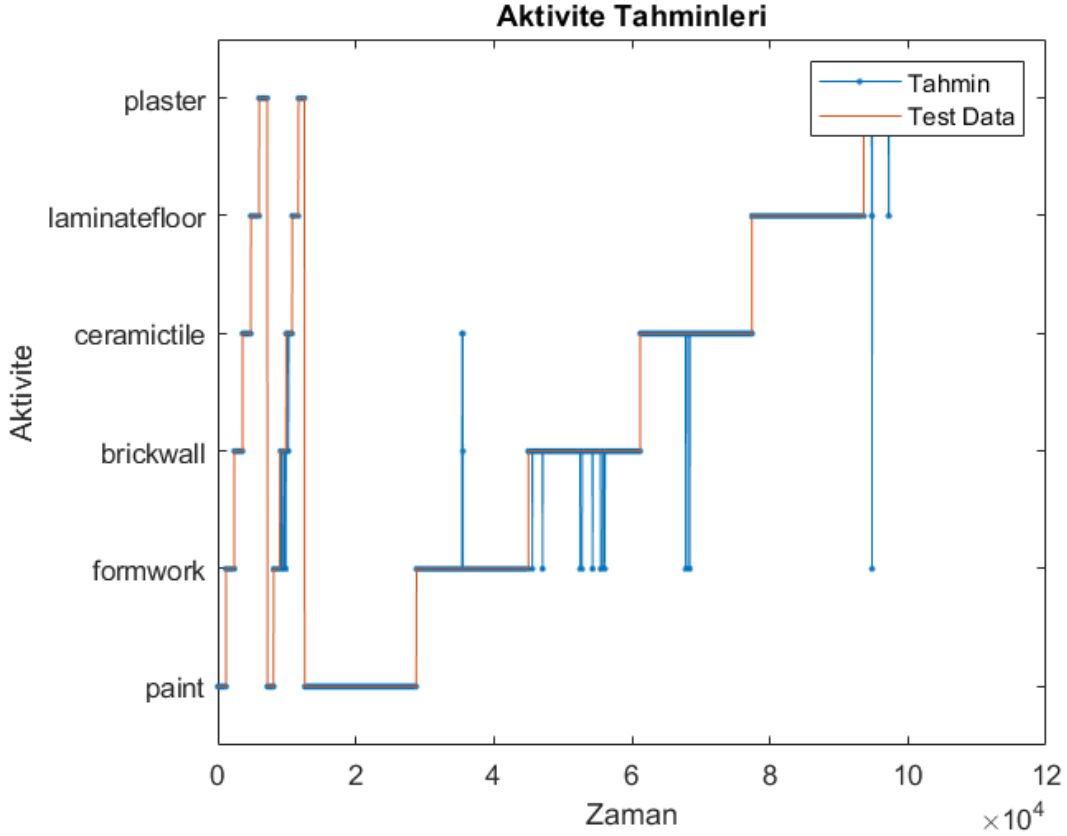
Sonrasında toplam eğitim setinin yaklaşık %5 i oranındaki 252 sn. olan test verilerine yeni veriler eklenerek 2196 sn. ye çıkartılmıştır. Böylece test verisi sayısı toplam veri setinin yaklaşık % 30'una ulaşmıştır. Bu yeni eğitim ve test verisi ile eğitim 39 sn. de tamamlanmış ve eğitim doğruluğu %100 ulaşmışken test verilerinde doğruluk oranı % 98,4 olmuştur.

**Confusion Matrix**

Output Class	paint	18300 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	18172 16.6%	1237 1.1%	195 0.2%	0 0.0%	10 0.0%	92.6% 7.4%
	brickwall	0 0.0%	21 0.0%	17063 15.5%	77 0.1%	0 0.0%	0 0.0%	99.4% 0.6%
	ceramictile	0 0.0%	107 0.1%	0 0.0%	18028 16.4%	0 0.0%	0 0.0%	99.4% 0.6%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	18300 16.7%	78 0.1%	99.6% 0.4%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	18212 16.6%	100% 0.0%
		100% 0.0%	99.3% 0.7%	93.2% 6.8%	98.5% 1.5%	100% 0.0%	99.5% 0.5%	98.4% 1.6%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
	<b>Target Class</b>							

Şekil 4.12 Yeni test verileri ile yapılan eğitim çalışması hata matrisi

Bu çalışmada boya ve parke işlerini %100 doğrulukla rahmin ederken en düşük doğruluk oranı %93,2 ile tuğla duvar işidir. Tuğla duvar işinin %6,8 lik kısmını kalıp işi olarak tahminlemiştir.



Şekil 4.13: Yeni test verileri ve tahminleri zaman-aktivite bazında gösterir grafik

Yeni test verileri ile yapılan çalışmaya ilişkin özet sonuçlar aşağıda sunulmuştur.

Tablo 4.7: Toplam yeni test verisi ve tahmin değerleri çıktısı

	FarkTabloR	FarkTabloN
1	"Toplam Test Veri"	109.800
2	"Toplam Test Sure"	2.196
3	"Dogru Tahmin Veri"	108.075
4	"Dogru Tahmin Sure"	2.162
5	"Yanlis Tahmin Veri"	1.725
6	"Yanlis Tahmin Sure"	34

Sonuç olarak toplam 2196 sn. yeni test verisinin 2162 sn. si doğru olarak tahminlenmiş olup sadece 34 sn. lik iş yanlış olarak tahminlenmiştir.

#### 4.1.2. Sensör Konum Verileri ile Aktivite Tanımlama (POS)

Çalışmanın bu bölümünde sadece baş, sağ el, sol el, sağ ayak konum verileri kullanılarak eğitim için sensörden elde edilen veriler 6 sn. lik (6x50=300 adet veri) gruplara ayrılarak 1097 adet

grup kategorize edilmiştir. XYZ ekseninde tüm konum verilerini içeren çalışmada eğitim için  $12 \times 300 \times 1097 = 3.949.200$  adet veri kullanılmıştır. Yine her bir iş kalemi için 300 adet gruplar halinde test grupları oluşturulmuştur. Araştırmada kullanılan 6 adet iş grubunun her birine ait 42 sn. lik test verisi kullanılmıştır. Bu noktadan hareketle testte  $6 \times 42 \times 50 \times 12 = 151.200$  adet veri kullanılmıştır. Araştırmada herbir iş için kullanılan bu veriler etiketlenerek eğitim ağına aktarılmıştır.

Sonrasında bu veriler yukarıda anlatmış olduğumuz eğitim ağına aktarılmıştır. Bu çalışmada derin öğrenme ağına farklı katmanlarda bir adet LSTM ve bir adet BiLSTM layer ve 2 adet dropout layer kullanılmıştır. Bu arada en etkin sonucu almak için öncelikle 6 farklı parametre kullanılarak eğitim sonuçları değerlendirilmiştir. Bu parametreler aşağıdaki tabloda gösterilmiştir.

Tablo 4.8: Sensör verileri için kullanılan hiperparametre setlerine ait değerler

<b>Eğitim Parametre</b>	<b>Set 1</b>	<b>Set 2</b>	<b>Set 3</b>	<b>Set 4</b>	<b>Set 5</b>	<b>Set 6</b>
MaxEpochs	10	15	20	23	25	30
LayerLstm	99	99	66	66	66	66
LayerBilstm	33	33	33	33	33	33
dropoutL1	0,20	0,20	0,33	0,33	0,33	0,20
dropoutL2	0,33	0,33	0,33	0,33	0,33	0,20

Yukarıdaki parametreler ile ağa ait eğitim sonrası sonuçlarını incelediğimizde;

Set 1 için eğitim süresi 00:03:06 olup, % 96,54 Eğitim doğruluk ve %99,91 test doğruluk oranına ulaşmıştır. Burada sadece test verilerinde tuğla duvar işinden küçük bir kısmını yanlış tahminlemiştir. Eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

Output Class	paint	formwork	brickwall	ceramictile	laminat地板	plaster	
paint	2100 16.7%	0 0.0%	10 0.1%	0 0.0%	0 0.0%	0 0.0%	99.5% 0.5%
formwork	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
brickwall	0 0.0%	0 0.0%	2090 16.6%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
laminat地板	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
	100% 0.0%	100% 0.0%	99.5% 0.5%	100% 0.0%	100% 0.0%	100% 0.0%	99.9% 0.1%
	paint	formwork	brickwall	ceramictile	laminat地板	plaster	

Şekil 4.14: Hiperparametre Set1 için hata matrisi görüntüsü

Set 2 için eğitim süresi 00:04:32 olup, % 98,84 Eğitim doğruluk ve %99,87 test doğruluk oranına ulaşmıştır. Burada sadece test verilerinde tuğla duvar işinden küçük bir kısmını yanlış tahminlemiştir. Set 2 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 2 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	18 0.1%	0 0.0%	0 0.0%	0 0.0%	99.2% 0.8%
	brickwall	0 0.0%	0 0.0%	2082 16.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminat地板	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	99.1% 0.9%	100% 0.0%	100% 0.0%	100% 0.0%	99.9% 0.1%
		<b>Target Class</b>						
		paint	formwork	brickwall	ceramictile	laminat地板	plaster	

Şekil 4.15: Hiperparametre Set2 için hata matrisi görüntüsü

Set 3 için eğitim süresi 00:05:46 olup, % 98,21 Eğitim doğruluk ve %99,83 test doğruluk oranına ulaşmıştır. Burada sadece test verilerinde tuğla duvar işinden küçük bir kısmını yanlış tahminlemiştir. Set 3 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.



**Training 3 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	18 0.1%	0 0.0%	0 0.0%	0 0.0%	99.2% 0.8%
	brickwall	0 0.0%	0 0.0%	2082 16.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminat地板	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	99.1% 0.9%	100% 0.0%	100% 0.0%	100% 0.0%	99.9% 0.1%
	paint	formwork	brickwall	ceramictile	laminat地板	plaster		
<b>Target Class</b>								

Şekil 4.16: Hiperparametre Set3 için hata matrisi görüntüsü

Set 4 için eğitim süresi 00:06:28 olup, % 98,95 Eğitim doğruluk ve %99,46 test doğruluk oranına ulaşmıştır. Burada sadece test verilerinde tuğla duvar işinden küçük bir kısmını yanlış tahminlemiştir. Set 4 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

Output Class	paint	formwork	brickwall	ceramictile	laminat地板	plaster	
paint	2100 16.7%	0 0.0%	62 0.5%	0 0.0%	0 0.0%	0 0.0%	97.1% 2.9%
formwork	0 0.0%	2100 16.7%	6 0.0%	0 0.0%	0 0.0%	0 0.0%	99.7% 0.3%
brickwall	0 0.0%	0 0.0%	2032 16.1%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
laminat地板	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
	100% 0.0%	100% 0.0%	96.8% 3.2%	100% 0.0%	100% 0.0%	100% 0.0%	99.5% 0.5%
	paint	formwork	brickwall	ceramictile	laminat地板	plaster	
	Target Class						

Şekil 4.17: Hiperparametre Set4 için hata matrisi görüntüsü

Set 5 için eğitim süresi 00:06:52 olup, % 96,37 Eğitim doğruluk ve %97,62 test doğruluk oranına ulaşmıştır. Set 5 en düşük test doğruluk oranına sahip parametre setidir. Bu eğitim setinde seramik döşeme işini laminat parke olarak yanlış tahminlemiştir. Set 5 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 5 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	1800 14.3%	0 0.0%	0 0.0%	100% 0.0%
	laminatetfloor	0 0.0%	0 0.0%	0 0.0%	300 2.4%	2100 16.7%	0 0.0%	87.5% 12.5%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	85.7% 14.3%	100% 0.0%	100% 0.0%	97.6% 2.4%
	paint	formwork	brickwall	ceramictile	laminatetfloor	plaster		
<b>Target Class</b>								

Şekil 4.18: Hiperparametre Set5 için hata matrisi görüntüsü

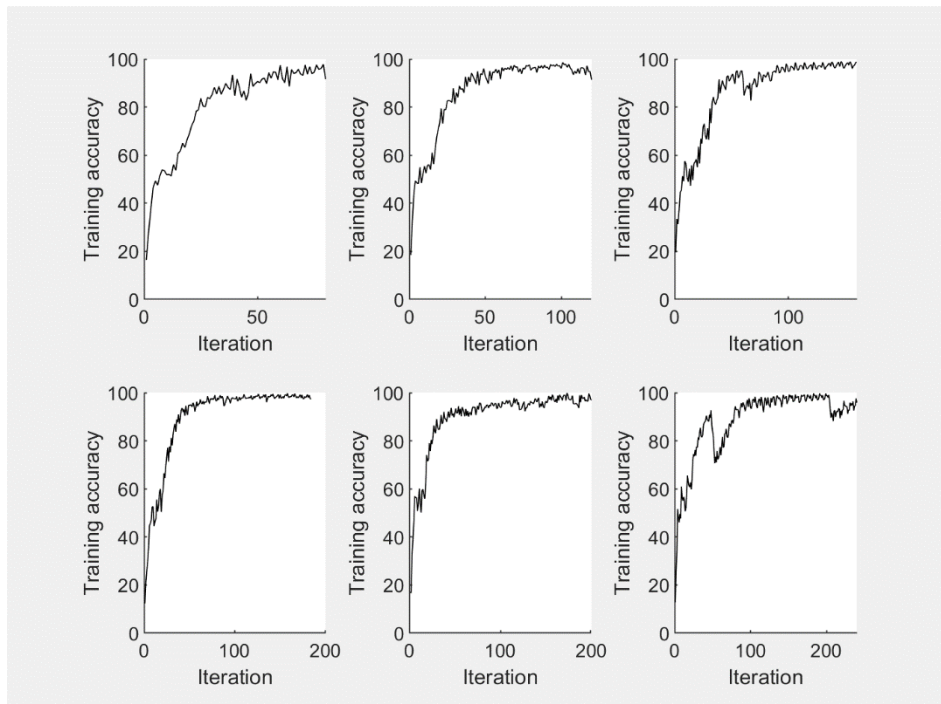
Set 6 için eğitim süresi 00:07:49 olup, % 98,67 Eğitim doğruluk ve %100 test doğruluk oranına ulaşmıştır. Eğitim süresi en uzun süren ve en yüksek eğitim doğruluk oranına sahip parametre setidir. Set 6 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 6 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatetfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	formwork	brickwall	ceramictile	laminatetfloor	plaster		
	<b>Target Class</b>							

Şekil 4.19: Hiperparametre Set6 için hata matrisi görüntüsü

Her bir sete ilişkin eğitim süreci doğruluk grafiği aşağıda sunulmuştur.



Şekil 4.20: Her bir parametre setine ait eğitim doğruluk oranı grafiği  
Eğitim sonrası sonuçlara ilişkin özet tablo aşağıda sunulmuştur.

Tablo 4.9: Eğitim hiperparametre setleri sonuç özeti


Eğitim Parametre		Set 1	Set 2	Set 3	Set 4	Set 5	Set 6
Parametreler	MaxEpochs	10	15	20	23	25	30
	LayerLstm	99	99	66	66	66	66
	LayerBilstm	33	33	33	33	33	33
	dropoutL1	0,20	0,20	0,33	0,33	0,33	0,20
	dropoutL2	0,33	0,33	0,33	0,33	0,33	0,20
Sonuçlar	Eğitim Süresi	00:03:06	00:04:32	00:05:46	00:06:28	00:06:52	00:07:49
	Train Accuracy	96,54%	<b>98,84%</b>	98,21%	98,95%	96,37%	98,67%
	Test Accuracy	99,91%	99,87%	99,83%	99,46%	97,62%	<b>100,00%</b>

Tablo incelendiğinde eğitim süresi 3-8 dk. arasında değişmekte iken eğitim doğruluğu en düşük % 96,37 olduğu gözlemlenmiştir. Eğitim setinin daha önce hiç görmediği test verilerinde ise doğruluk oranı en düşük % 97,62 olmasına karşın %100 doğruluk oranı da yakalanmıştır. Eğitim doğruluk ortalaması % 97,93 iken test doğruluk oranı ortalaması %99,45 olarak hesaplanmıştır. Her sette yanlış tahmin edilen veriler incelendiğinde bunların ağırlıklı olarak tuğla duvar işinin küçük bir kısmının kalıp işi olarak ve seramik döşeme işçiliğinin laminat parke olarak tahminlendiği görülmektedir. Çok az bir yanlış tahmin olasa dahi bu tahminlerin toplanan veriler ile tutarlı olduğunu görmekteyiz. Sensör verilerinden vücut konumlu tahminleme olduğu için örneğin her ikiside ayakta yapılan tuğla duvar ve kalıp işi arasında yanlış tahmin bulunmuştur. Bir diğer örnek benzer şekilde yanlış tahminlenen seramik ve laminat parke işinin her ikiside çömelerek yerde yapılmaktadır. Çalışma konumları tamamen farklı olan diğer aktiviteler arasında bir yanlış tahmin yer almamıştır.

Sonraki adımda yukarıdaki verilerin ışığında aşağıda belirtilen parametrelerle bir eğitim daha gerçekleştirilmiştir.

```
MaxEpochs = 30;
numHiddenUnits1 = 66;
numHiddenUnits2 = 33;
dropoutLayer1 = 0.33;
dropoutLayer2 = 0.33;
```

Bu nihai karar verilen parametreler ile eğitim 41 saniyede tamamlanmıştır. Eğitimde % 99,98 doğruluk oranına ulaşılırken test verilerinde % 100 doğruluk oranına ulaşılmıştır.



Şekil 4.21: Sensör konum verileri derin öğrenme ağı nihai eğitim süreci ekran görüntüsü

**Confusion Matrix**


<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
	<b>Target Class</b>							

Şekil 4.22: Sensör konum verileri nihai eğitim hata matrisi ekran görüntüsü

Eğitim sonucunda 252 sn. 12600 adet test verisinin tümü doğru olarak tahmin edilmiştir.

Tablo 4.10: Toplam test verisi ve tahmin değerleri çıktısı

	FarkTabloR	FarkTabloN
1	"Toplam Test Veri"	12600
2	"Toplam Test Sure"	252
3	"Dogru Tahmin Veri"	12600
4	"Dogru Tahmin Sure"	252
5	"Yanlis Tahmin Veri"	0
6	"Yanlis Tahmin Sure"	0



Şekil 4.23: Test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik

Sonraki aşamada aşağıdaki kod ile tahminlerin % oranı incelenmiştir.

```
WF=table(YTest1x',YPred1x',scr1(1,:)',scr1(2,:)',scr1(3,:)',scr1(4,:)',scr1(5,
:)',scr1(6,:)',...
'VariableNames',{'Test','Pred','Paint','Form','Brick','Ceramic','Laminate','Pl
aster'})
statarray = grpstats(WF,{'Pred'},{'min','max','mean'},...
'DataVars',{'Paint','Form','Brick','Ceramic','Laminate','Plaster'})
```

Tablo 4.11: İş bazında test verileri tahmin oranlarını gösterir tablo

Test	Pred	Paint	Form	Brick	Ceramic	Laminate	Plaster
paint	paint	0.9331	0.0090	0.0111	0.0101	0.0132	0.0235
paint	paint	0.9466	0.0074	0.0092	0.0080	0.0097	0.0191
paint	paint	0.9582	0.0059	0.0076	0.0061	0.0067	0.0154
paint	paint	0.9676	0.0046	0.0063	0.0046	0.0044	0.0125
paint	paint	0.9750	0.0036	0.0052	0.0034	0.0029	0.0101
paint	paint	0.9806	0.0027	0.0042	0.0025	0.0019	0.0081
paint	paint	0.9849	0.0020	0.0035	0.0018	0.0013	0.0066
paint	paint	0.9880	0.0015	0.0029	0.0014	0.0009	0.0053
paint	paint	0.9904	0.0011	0.0024	0.0011	0.0007	0.0043
paint	paint	0.9921	0.0009	0.0021	0.0009	0.0006	0.0035
paint	paint	0.9934	0.0007	0.0018	0.0007	0.0005	0.0029



Tablo 4.12: İş bazında tahminlerin yüzdesel dağılım özeti

Work	Min	Max	Ortalama
1 paint	<b>86,45%</b>	99,83%	99,60%
2 formwork	85,01%	99,85%	99,46%
3 brickwall	58,93%	99,46%	96,17%
4 ceramictile	82,38%	99,91%	99,77%
5 laminatefloor	85,10%	<b>99,94%</b>	<b>99,83%</b>
6 plaster	82,31%	99,86%	99,62%

Sonuçlara göre en düşük yani en kötü doğruluk tahmini % 58,93 ile tuğla duvar işinde görülmüştür. En başarılı tahmin ise % 99,83 ortalama ile laminat parke işinde olmuştur. Sıva işinde en düşük tahmin oranı % 91,30 olarak gerçekleşmiştir.

Sonrasında test verisi kullanılarak çalışan ustanın hangi işte ne kadar süre çalıştığı hesaplanmıştır.

Tablo 4.13: İşçinin hangi işi ne kadar süre ile yaptığını gösterir program çıktısı

	Var1	GroupCount	WorkTime
1	paint	2100	42
2	formwork	2100	42
3	brickwall	2100	42
4	ceramictile	2100	42
5	laminatefloor	2100	42
6	plaster	2100	42

Sonuç olarak sadece sağ el, sol el, sağ ayak ve baş üzerinde yer alan sensörlerin konum verileri kullanılarak, oluşturulan derin öğrenme ağı ve parametreler ile, bir ustanın çalıştığı toplam 252 sn. süre içinde hangi işleri ne kadar süre ile yaptığı %100 doğruluk oranı ile tahmin edilmiştir.

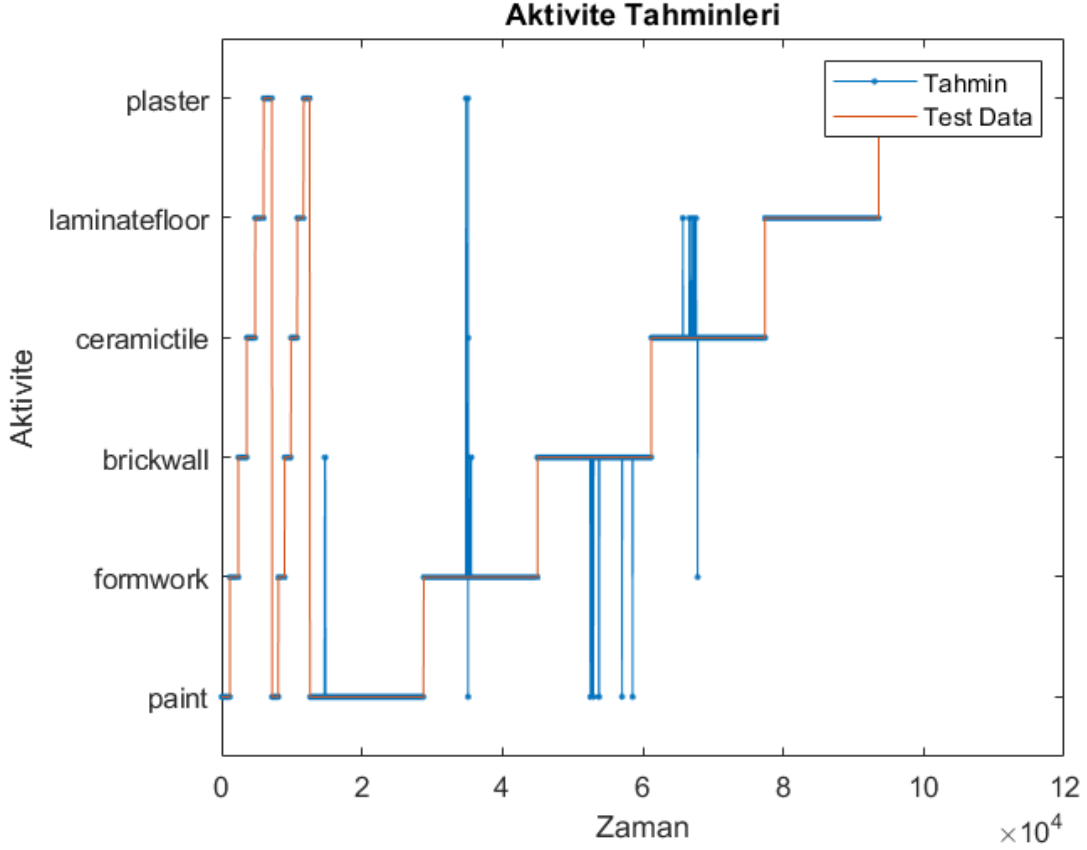
Sonrasında toplam eğitim setinin yaklaşık %5 i oranındaki 252 sn. olan test verilerine yeni veriler eklenerek 2196 sn. ye çıkartılmıştır. Böylece test verisi sayısı toplam veri setinin yaklaşık % 30'una ulaşmıştır. Bu yeni eğitim ve test verisi ile eğitim 39 sn. de tamamlanmış ve eğitim doğruluğu %98,35'e ulaşmışken test verilerinde doğruluk oranı % 99,15 olmuştur.

**Confusion Matrix**

<b>Output Class</b>	paint	<b>18257</b> 16.6%	<b>10</b> 0.0%	<b>316</b> 0.3%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>98.2%</b> 1.8%
	formwork	<b>0</b> 0.0%	<b>18088</b> 16.5%	<b>0</b> 0.0%	<b>1</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100.0%</b> 0.0%
	brickwall	<b>43</b> 0.0%	<b>159</b> 0.1%	<b>17984</b> 16.4%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>98.9%</b> 1.1%
	ceramictile	<b>0</b> 0.0%	<b>22</b> 0.0%	<b>0</b> 0.0%	<b>17953</b> 16.4%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>99.9%</b> 0.1%
	laminatelfloor	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>346</b> 0.3%	<b>18300</b> 16.7%	<b>0</b> 0.0%	<b>98.1%</b> 1.9%
	plaster	<b>0</b> 0.0%	<b>21</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>18300</b> 16.7%	<b>99.9%</b> 0.1%
		<b>99.8%</b> 0.2%	<b>98.8%</b> 1.2%	<b>98.3%</b> 1.7%	<b>98.1%</b> 1.9%	<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>99.2%</b> 0.8%
	<b>paint</b>	<b>formwork</b>	<b>brickwall</b>	<b>ceramictile</b>	<b>laminatelfloor</b>	<b>plaster</b>		
	<b>Target Class</b>							

Şekil 4.24: Yeni test verileri ile yapılan eğitim çalışması hata matrisi

Bu çalışmada sıva ve parke işlerini %100 doğrulukla rahmin ederken en düşük doğruluk oranı %98,1 ile seramik döşeme işi olmuştur. Seramik döşeme işinin %1,9 luk kısmını laminat parke olarak tahminlemiştir. Bu çalışmada pozisyon verileri kullanıldığı için düşündüğümüzde seramik ve laminat parke işininin her ikisinde çömelme pozisyonunda yerde yapılmaktadır. Bu iki çalışmaya ilişkin 3 boyutlu animasyonlarda incelendiğinde vücut pozisyonlarının birbirine yakın olduğu görülmüştür.



Şekil 4.25: Yeni test verileri ve tahminleri zaman-aktivite bazında gösterir grafik  
Çalışmaya ilişkin test verilerinin özet tahmin sonuçları aşağıda sunulmuştur.

Tablo 4.14: Toplam yeni test verisi ve tahmin değerleri çıktısı

	FarkTabloR	FarkTabloN
1	"Toplam Test Veri"	109.800
2	"Toplam Test Sure"	2.196
3	"Dogru Tahmin Veri"	108.882
4	"Dogru Tahmin Sure"	2.178
5	"Yanlis Tahmin Veri"	918
6	"Yanlis Tahmin Sure"	18

Sonuç olarak sadece vücut pozisyon verileri kullanılarak yapılan toplam 2196 sn. test verisinin 2178 sn. si doğru olarak tahminlenmiş olup sadece 18 sn. lik iş yanlış olarak tahminlenmiştir.

#### 4.1.3. Sensör İvme ve Konum Verileri ile Aktivite Tanımlama (ACCPOS)

Çalışmanın bu bölümünde yukarıda anlatılan Çalışma 1 sağ ve sol el ivme sensörü verileri ile Çalışma 2 sağ el, sol el, baş ve ayak sensör konum verileri birleştirilmiştir. Bu eğitim için

sensörden elde edilen veriler 6 sn. lik ( $6 \times 50 = 300$  adet veri) gruplara ayrılarak 1097 adet grup kategorize edilmiştir. XYZ ekseninde hem ivme hem konum verilerini içeren çalışmada eğitim için  $18 \times 300 \times 1097 = 5.923.800$  adet veri kullanılmıştır. Yine her bir iş kalemi için yine 300 adet gruplar halinde test grupları oluşturulmuştur. Test verileri eğitim setinde kullanılmamıştır ve bu veriler eğitilmiş ağıın ilk defa göreceği veriler olup derin öğrenme ağıının doğruluğunun gerçek anlamda anlaşılması açısından önemli bir durum oluşturmaktadır. Araştırmada kullanılan 6 adet iş grubunun her birine ait 42 sn. lik test verisi kullanılmıştır. Bu noktadan hareketle testte  $6 \times 42 \times 50 \times 18 = 226.800$  adet veri kullanılmıştır. Araştırmada herbir iş için kullanılan bu veriler etiketlenerek eğitim ağına aktarılmıştır.

Sonrasında bu veriler yukarıda anlatmış olduğumuz eğitim ağına aktarılmıştır. Bu çalışmada derin öğrenme ağıında farklı katmanlarda bir adet LSTM ve bir adet BiLSTM layer ve 2 adet dropout layer kullanılmıştır. Bu arada en etkin sonucu almak için öncelikle 6 farklı parametre kullanılarak eğitim sonuçları değerlendirilmiştir. Bu parametreler aşağıdaki tabloda gösterilmiştir.

Tablo 4.15: Sensör ve konum verileri için kullanılan hiperparametre setlerine ait değerler

<b>Eğitim Parametre</b>	<b>Set 1</b>	<b>Set 2</b>	<b>Set 3</b>	<b>Set 4</b>	<b>Set 5</b>	<b>Set 6</b>
MaxEpochs	10	15	20	23	25	30
LayerLstm	99	99	99	99	99	99
LayerBilstm	33	33	33	33	33	33
dropoutL1	0,33	0,33	0,33	0,33	0,33	0,33
dropoutL2	0,33	0,33	0,33	0,33	0,33	0,33

Yukarıdaki parametreler ile eğitim ağına ait eğitim sonrası sonuçları incelediğimizde;

Set 1 için eğitim süresi 00:03:16 olup, % 99,34 Eğitim doğruluk ve %99,74 test doğruluk oranına ulaşmıştır. Burada sadece test verilerinde tuğla duvar işinin küçük bir kısmını kalıp işi olarak yanlış tahminlemiştir. Eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 1 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	21 0.2%	0 0.0%	0 0.0%	0 0.0%	99.0% 1.0%
	brickwall	0 0.0%	0 0.0%	2079 16.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	99.0% 1.0%	100% 0.0%	100% 0.0%	100% 0.0%	99.8% 0.2%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
<b>Target Class</b>								

Şekil 4.26: Hiperparametre Set1 için hata matrisi görüntüsü

Set 2 için eğitim süresi 00:04:42 olup, % 99,30 Eğitim doğruluk ve %100 test doğruluk oranına ulaşmıştır. Set 2 %100 test doğruluk oranına ulaşan 3 parametre setinden birisidir. Set 2 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 2 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
	<b>Target Class</b>							

Şekil 4.27: Hiperparametre Set2 için hata matrisi görüntüsü

Set 3 için eğitim süresi 00:05:59 olup, % 99,54 Eğitim doğruluk ve %100 test doğruluk oranına ulaşmıştır. Set 3 %100 test doğruluk oranına ulaşan 3 parametre setinden birisidir. Set 3 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 3 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
	<b>Target Class</b>							

Şekil 4.28: Hiperparametre Set3 için hata matrisi görüntüsü

Set 4 için eğitim süresi 00:06:42 olup, % 99,67 Eğitim doğruluk ve %97,92 test doğruluk oranına ulaşmıştır. En düşük test doğruluk oranına sahip çalışma olup, Set 1 'e benzer şekilde test verilerinde tuğla duvar işinin küçük bir kısmını kalıp işi olarak yanlış tahminlemiştir. Bununla birlikte çok küçük bir kısımda seramik döşeme işini laminat parke olarak yanlış tahminlemiştir. Set 4 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 4 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	256 2.0%	0 0.0%	0 0.0%	0 0.0%	89.1% 10.9%
	brickwall	0 0.0%	0 0.0%	1844 14.6%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2094 16.6%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	6 0.0%	2100 16.7%	0 0.0%	99.7% 0.3%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	87.8% 12.2%	99.7% 0.3%	100% 0.0%	100% 0.0%	97.9% 2.1%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
<b>Target Class</b>								

Şekil 4.29: Hiperparametre Set4 için hata matrisi görüntüsü

Set 5 için eğitim süresi 00:07:06 olup, % 99,96 Eğitim doğruluk ve %99,27 test doğruluk oranına ulaşmıştır. Set 5 en düşük test doğruluk oranına sahip parametre setidir. Bu eğitim setinde Set 1 ve Set 4'e benzer şekilde test verilerinde tuğla duvar işinin küçük bir kısmını kalıp işi olarak yanlış tahminlemiştir. Bununla birlikte çok küçük bir kısımda seramik döşeme işini laminat parke olarak yanlış tahminlemiştir. Set 5 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.



**Training 5 Confusion Matrix**

<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	38 0.3%	0 0.0%	0 0.0%	0 0.0%	98.2% 1.8%
	brickwall	0 0.0%	0 0.0%	2062 16.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2046 16.2%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	54 0.4%	2100 16.7%	0 0.0%	97.5% 2.5%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	98.2% 1.8%	97.4% 2.6%	100% 0.0%	100% 0.0%	99.3% 0.7%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
<b>Target Class</b>								

Şekil 4.30: Hiperparametre Set5 için hata matrisi görüntüsü


Set 6 için eğitim süresi 00:08:15 olup, % 99,99 Eğitim doğruluk ve %100 test doğruluk oranına ulaşmıştır. Tüm parametre setleri içinde hem eğitim hem test doğruluk açısından en başarılı settir. Bu eğitim setinde de sadece tuğla duvar işi, kalıp işi olarak yanlış tahminlenmiştir. Set 6 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 6 Confusion Matrix**

<b>Output Class</b>	paint	<b>2100</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	formwork	<b>0</b> 0.0%	<b>2100</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	brickwall	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>2100</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	ceramictile	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>2100</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	laminatelfloor	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>2100</b> 16.7%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	plaster	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>2100</b> 16.7%	<b>100%</b> 0.0%
		<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>100%</b> 0.0%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
	<b>Target Class</b>							

Şekil 4.31: Hiperparametre Set6 için hata matrisi görüntüsü

Her bir sete ilişkin iterasyon ve eğitim doğruluk grafiği aşağıda sunulmuştur.



Şekil 4.32: Her bir parametre setine ait eğitim doğruluk oranı grafiği  
Eğitim sonrası sonuçlara ilişkin özet tablo aşağıda sunulmuştur.

Tablo 4.16: Eğitim hiperparametre setleri sonuç özeti

Eğitim Parametre		Set 1	Set 2	Set 3	Set 4	Set 5	Set 6
Parametreler	MaxEpochs	10	15	20	23	25	30
	LayerLstm	99	99	99	99	99	99
	LayerBilstm	33	33	33	33	33	33
	dropoutL1	0,33	0,33	0,33	0,33	0,33	0,33
	dropoutL2	0,33	0,33	0,33	0,33	0,33	0,33
Sonuçlar	Eğitim Süresi	00:03:16	00:04:42	00:05:59	00:06:42	00:07:06	00:08:15
	Train Accuracy	99,34%	99,30%	99,54%	99,67%	99,96%	<b>99,99%</b>
	Test Accuracy	99,74%	<b>100,00%</b>	<b>100,00%</b>	97,92%	99,27%	<b>100,00%</b>

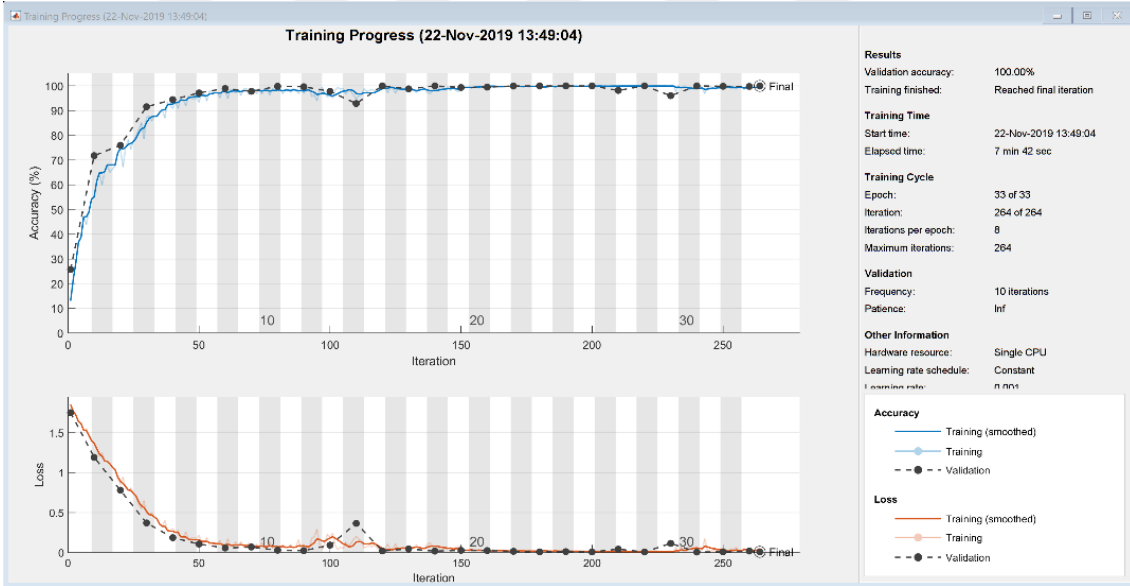
Tablo incelendiğinde eğitim süresi 3-8 dk. arasında değişmekte iken eğitim doğruluğu en düşük % 99,30 olduğu gözlemlenmiştir. Eğitim setinin daha önce hiç görmediği test verilerinde ise doğruluk oranı en düşük % 97,27 olmasına karşın üç parametre setinde %100 doğruluk oranı da yakalanmıştır. Diğer çalışmalarda sadece bir parametre setinde %100 doğruluk oranı yakalanmışken bu çalışmada üç parametre setinde %100 doğruluk oranı yakalanmıştır. Eğitim doğruluk ortalaması % 99,63 iken test doğruluk oranı ortalaması %99,49 olarak hesaplanmıştır.

Her sette yanlış tahmin edilen veriler incelendiğinde bunların ağırlıklı olarak tuğla duvar işinin küçük bir kısmının kalıp işi olarak tahminlendiği görülmektedir.

Sonraki adımda yukarıdaki verilerin ışığında aşağıda belirtilen parametrelerle nihai eğitim gerçekleştirilmiştir.

```
MaxEpochs = 33;
numHiddenUnits1 = 66;
numHiddenUnits2 = 33;
dropoutLayer1 = 0.33;
dropoutLayer2 = 0.33;
```

Bu nihai karar verilen parametreler ile eğitim 7 dakika 42 saniyede tamamlanmıştır. Eğitimde % 99,91 doğruluk oranına ulaşılırken test verilerinde % 100 doğruluk oranına ulaşılmıştır.



Şekil 4.33: Sensör konum ve ivme verileri derin öğrenme ağı nihai eğitim süreci ekran görüntüsü

**Confusion Matrix**


<b>Output Class</b>	paint	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2100 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	formwork	brickwall	ceramictile	laminatelfloor	plaster		
	<b>Target Class</b>							

Şekil 4.34: Sensör konum verileri nihai eğitim hata matrisi ekran görüntüsü

Görüldüğü üzere eğitim sonucunda 252 sn. 12600 adet verinin tümü doğru olarak tahmin edilmiştir.

Tablo 4.17: Toplam test verisi ve tahmin değerleri çıktısı

	FarkTabloR	FarkTabloN
1	"Toplam Test Veri"	12600
2	"Toplam Test Sure"	252
3	"Dogru Tahmin Veri"	12600
4	"Dogru Tahmin Sure"	252
5	"Yanlis Tahmin Veri"	0
6	"Yanlis Tahmin Sure"	0



Şekil 4.35: Test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik  
Sonraki aşamada aşağıdaki kod ile tahminlerin % oranı incelenmiştir.

```
WF=table(YTest1x',YPred1x',scr1(1,:)',scr1(2,:)',scr1(3,:)',scr1(4,:)',scr1(5,
:)',scr1(6,:)',...
'VariableNames',{'Test','Pred','Paint','Form','Brick','Ceramic','Laminate','Pl
aster'})
statarray = grpstats(WF,{'Pred'},{'min','max','mean'},...
'DataVars',{'Paint','Form','Brick','Ceramic','Laminate','Plaster'})
```

Tablo 4.18: İş bazında test verileri tahmin oranlarını gösterir tablo

Test	Pred	Paint	Form	Brick	Ceramic	Laminate	Plaster
paint	paint	0.7583	0.0260	0.0526	0.0702	0.0393	0.0536
paint	paint	0.8035	0.0228	0.0428	0.0568	0.0298	0.0443
paint	paint	0.8499	0.0191	0.0324	0.0422	0.0211	0.0352
paint	paint	0.8943	0.0149	0.0224	0.0287	0.0138	0.0260
paint	paint	0.9324	0.0106	0.0141	0.0177	0.0081	0.0172
paint	paint	0.9602	0.0070	0.0082	0.0101	0.0044	0.0102
paint	paint	0.9774	0.0044	0.0046	0.0056	0.0023	0.0057
paint	paint	0.9870	0.0027	0.0027	0.0032	0.0012	0.0032
paint	paint	0.9922	0.0017	0.0016	0.0019	0.0007	0.0018
paint	paint	0.9951	0.0011	0.0010	0.0012	0.0004	0.0011
paint	paint	0.9966	0.0008	0.0007	0.0009	0.0003	0.0007

Tablo 4.19: İş bazında tahminlerin yüzdesel dağılım özeti

Work	Min	Max	Ortalama
1 paint	69,62%	99,94%	99,59%
2 formwork	88,12%	<b>99,96%</b>	99,70%
3 brickwall	57,92%	99,85%	97,96%
4 ceramictile	73,65%	99,90%	99,62%
5 laminatefloor	<b>94,36%</b>	99,93%	<b>99,83%</b>
6 plaster	63,10%	99,93%	99,10%

Sonuçlara göre en düşük yani en kötü doğruluk tahmini % 57,92 ile tuğla duvar işinde görülmüştür. Toplamda 6 adet iş aktivitesi ile bu çalışmanın yapıldığı düşünüldüğünde en kötü sonucun bile aslında ne kadar başarılı bir tahmin olduğu görülmektedir. En başarılı tahmin ise % 99,83 ortalama ile laminat parke işinde olmuştur. Laminat parke işinde en düşük tahmin oranı % 94,36 olarak gerçekleşmiştir.

Sonrasında test verisi kullanılarak çalışan ustanın hangi işte ne kadar süre çalıştığı aşağıdaki kod ile hesaplanmıştır.

```
WorkFreqTable=table(YPred1x(:));
%WorkFreqTable=cell2table(tabulate(YPred1x))
WorkFreq = groupsummary(WorkFreqTable, "Var1");
WorkFreq.WorkTime = WorkFreq.GroupCount/50
```

Tablo 4.20: İşçinin hangi işi ne kadar süre ile yaptığını gösterir program çıktısı

	Var1	GroupCount	WorkTime
1	paint	2100	42
2	formwork	2100	42
3	brickwall	2100	42
4	ceramictile	2100	42
5	laminatfloor	2100	42
6	plaster	2100	42

Sonuç olarak sadece sağ el ve sol el ivme sensörü verileri ile baş, ayak, sağ el, sol el sensör konum verileri kullanılarak, oluşturulan derin öğrenme ağı ve parametreler ile, bir ustanın çalıştığı toplam 252 sn. süre içinde hangi işleri ne kadar süre ile yaptığı %100 doğruluk oranı ile tahmin edilmiştir.

Sonrasında toplam eğitim setinin yaklaşık %5 i oranındaki 252 sn. olan test verilerine yeni veriler eklenerek 2196 sn. ye çıkartılmıştır. Böylece test verisi sayısı toplam veri setinin

yaklaşık % 30'una ulaşmıştır. Bu yeni eğitim ve test verisi ile eğitim 45 sn. de tamamlanmış ve eğitim doğruluğu %99,13'e ulaşmışken test verilerinde doğruluk oranı % 99,37 olmuştur.


**Confusion Matrix**

<b>Output Class</b>	paint	18275 16.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	formwork	7 0.0%	18084 16.5%	440 0.4%	0 0.0%	0 0.0%	13 0.0%	97.5% 2.5%
	brickwall	18 0.0%	216 0.2%	17860 16.3%	0 0.0%	0 0.0%	0 0.0%	98.7% 1.3%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	18300 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminat地板	0 0.0%	0 0.0%	0 0.0%	0 0.0%	18300 16.7%	0 0.0%	100% 0.0%
	plaster	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	18287 16.7%	100% 0.0%
		99.9% 0.1%	98.8% 1.2%	97.6% 2.4%	100% 0.0%	100% 0.0%	99.9% 0.1%	99.4% 0.6%
		<b>Target Class</b>						
		paint	formwork	brickwall	ceramictile	laminat地板	plaster	

Şekil 4.36: Yeni test verileri ile yapılan eğitim çalışması hata matrisi

Bu çalışmada seramik ve parke işlerini %100 doğrulukla tahmin ederken en düşük doğruluk oranı %97,6 ile tuğla duvar işi olmuştur. Tuğla duvar işinin %2,4 lik kısmını kalıp işi olarak tahminlemiştir. Sadece ivme sensörü verileri kullanılan çalışmada da en düşük tahmin oranı %6,4 hata ile tuğla duvar işi kalıp işi olarak tahminlenmesidir. Sadece konum verilerinin kullanıldığı çalışmada ise en yüksek hata laminat parke ve seramik döşeme arasında olmuştur. Bu çalışmada ivme ve pozisyon verilerinin birlikte kullanımının ivme sensöründeki tuğla duvar hatalı tahmin oranı ile sadece konum verilerindeki seramik döşeme yanlış tahmin oranlarını düşürdüğü görülmektedir.





Şekil 4.37: Yeni test verileri ve tahminleri zaman-aktivite bazında gösterir grafik  
Çalışmaya ilişkin test verilerinin özet tahmin sonuçları aşağıda sunulmuştur.

Tablo 4.21: Toplam yeni test verisi ve tahmin değerleri çıktısı

	<b>FarkTabloR</b>	<b>FarkTabloN</b>
1	"Toplam Test Veri"	109.800
2	"Toplam Test Sure"	2.196
3	"Dogru Tahmin Veri"	109.106
4	"Dogru Tahmin Sure"	2.182
5	"Yanlis Tahmin Veri"	694
6	"Yanlis Tahmin Sure"	14

Sonuç olarak sadece vücut pozisyon verileri kullanılarak yapılan toplam 2196 sn. test verisinin 2182 sn. si doğru olarak tahminlenmiş olup sadece 14 sn. lik iş yanlış olarak tahminlenmiştir.



Yukarıdaki parametreler ile eğitim ağına ait eğitim sonrası sonuçları incelediğimizde;

Set 1 için eğitim süresi 00:31:19 olup, % 93,67 Eğitim doğruluk ve %93,18 test doğruluk oranına ulaşmıştır. Set 1 parametreleri test doğruluk oranı %100 ü bulan tek parametre setidir. Eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**1. Training Confusion Matrix**

Output Class	paint	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	plaster	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	926 12.9%	211 2.9%	0 0.0%	0 0.0%	81.4% 18.6%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	983 13.7%	0 0.0%	0 0.0%	100% 0.0%
	laminat地板	0 0.0%	0 0.0%	25 0.3%	0 0.0%	1200 16.7%	0 0.0%	98.0% 2.0%
	formwork	0 0.0%	0 0.0%	249 3.5%	6 0.1%	0 0.0%	1200 16.7%	82.5% 17.5%
		100% 0.0%	100% 0.0%	77.2% 22.8%	81.9% 18.1%	100% 0.0%	100% 0.0%	93.2% 6.8%
	paint	plaster	brickwall	ceramictile	laminat地板	formwork		
		Target Class						

Şekil 4.38: Hiperparametre Set1 için hata matrisi görüntüsü

Set 2 için eğitim süresi 00:33:00 olup, % 95,20 Eğitim doğruluk ve %99,83 test doğruluk oranına ulaşmıştır. Burada sadece test verilerinde tuğla duvar ve seramik işinden küçük bir kısmını yanlış tahminlemiştir. Set 2 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**1. Training Confusion Matrix**

<b>Output Class</b>	paint	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	plaster	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	1190 16.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	1198 16.6%	0 0.0%	0 0.0%	100% 0.0%
	laminatetfloor	0 0.0%	0 0.0%	10 0.1%	2 0.0%	1200 16.7%	0 0.0%	99.0% 1.0%
	formwork	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	99.2% 0.8%	99.8% 0.2%	100% 0.0%	100% 0.0%	99.8% 0.2%
	paint	plaster	brickwall	ceramictile	laminatetfloor	formwork		
<b>Target Class</b>								

Şekil 4.39: Hiperparametre Set2 için hata matrisi görüntüsü

Set 3 için eğitim süresi 00:33:31 olup, % 93,52 Eğitim doğruluk ve %90,58 test doğruluk oranına ulaşmıştır. Set 3 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**1. Training Confusion Matrix**

<b>Output Class</b>	paint	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	plaster	0 0.0%	1200 16.7%	0 0.0%	35 0.5%	0 0.0%	0 0.0%	97.2% 2.8%
	brickwall	0 0.0%	0 0.0%	613 8.5%	31 0.4%	24 0.3%	0 0.0%	91.8% 8.2%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	1134 15.8%	1 0.0%	0 0.0%	99.9% 0.1%
	laminatetfloor	0 0.0%	0 0.0%	287 4.0%	0 0.0%	1175 16.3%	0 0.0%	80.4% 19.6%
	formwork	0 0.0%	0 0.0%	300 4.2%	0 0.0%	0 0.0%	1200 16.7%	80.0% 20.0%
		100% 0.0%	100% 0.0%	51.1% 48.9%	94.5% 5.5%	97.9% 2.1%	100% 0.0%	90.6% 9.4%
	<b>Target Class</b>							
	paint	plaster	brickwall	ceramictile	laminatetfloor	formwork		

Şekil 4.40: Hiperparametre Set3 için hata matrisi görüntüsü

Set 4 için eğitim süresi 00:33:44 olup, % 94,83 Eğitim doğruluk ve %100,00 test doğruluk oranına ulaşmıştır. Set 4 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**1. Training Confusion Matrix**

<b>Output Class</b>	paint	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	plaster	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatetfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	100% 0.0%
	formwork	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	plaster	brickwall	ceramictile	laminatetfloor	formwork		
	<b>Target Class</b>							

Şekil 4.41: Hiperparametre Set4 için hata matrisi görüntüsü

Set 5 için eğitim süresi 00:33:58 olup, % 95,30 Eğitim doğruluk ve %100 test doğruluk oranına ulaşmıştır. Set 5 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**1. Training Confusion Matrix**

<b>Output Class</b>	paint	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	plaster	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatetfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	100% 0.0%
	formwork	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	plaster	brickwall	ceramictile	laminatetfloor	formwork		
	<b>Target Class</b>							

Şekil 4.42: Hiperparametre Set5 için hata matrisi görüntüsü

Set 6 için eğitim süresi 00:09:29 olup, % 99,71 Eğitim doğruluk ve %100 test doğruluk oranına ulaşmıştır. Set 6 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

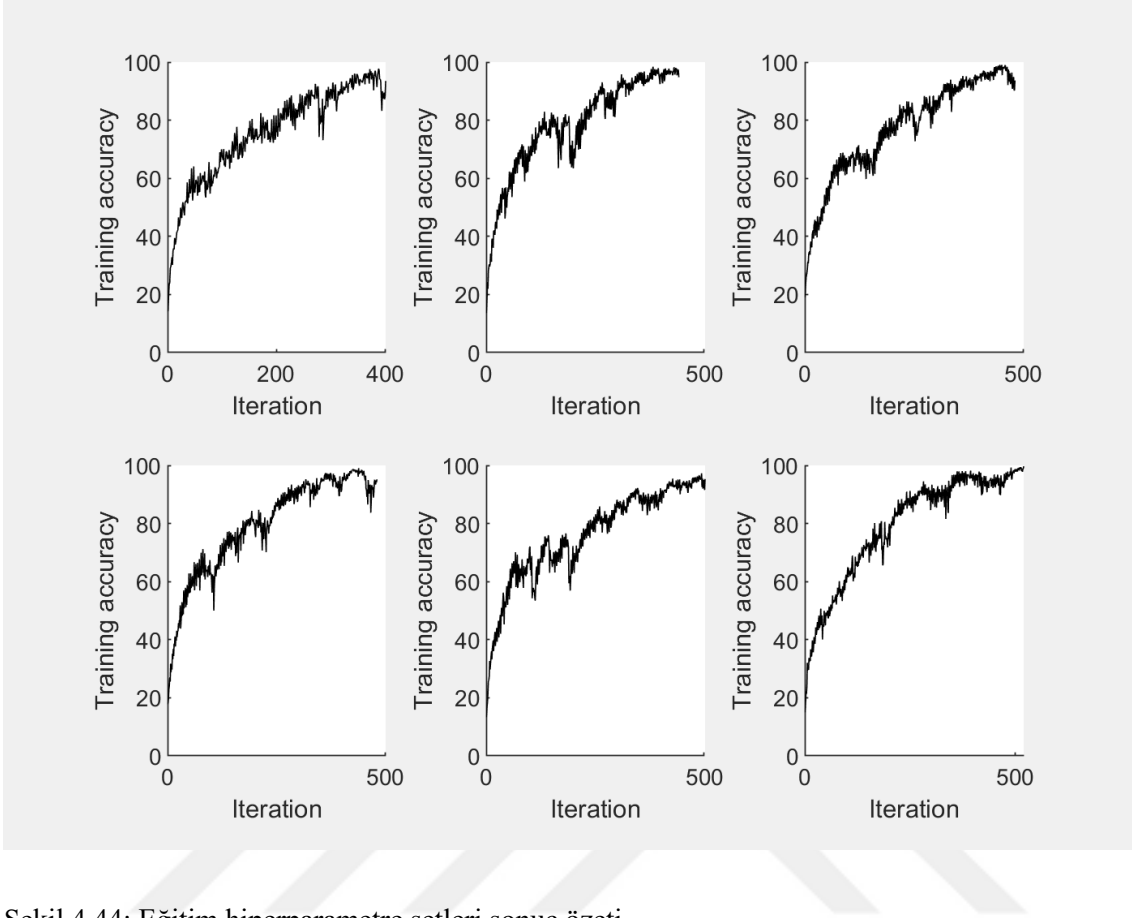
**1. Training Confusion Matrix**

<b>Output Class</b>	paint	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	plaster	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminat地板	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	100% 0.0%
	formwork	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	plaster	brickwall	ceramictile	laminat地板	formwork		
	<b>Target Class</b>							

Şekil 4.43: Hiperparametre Set6 için hata matrisi görüntüsü

Her bir sete ilişkin iterasyon ve eğitim doğruluk grafiği aşağıda sunulmuştur.





Şekil 4.44: Eğitim hiperparametre setleri sonuç özeti

Eğitim sonrası sonuçlara ilişkin özet tablo aşağıda sunulmuştur.

Tablo 4.23: Eğitim hiperparametre setleri sonuç özeti

Eğitim Parametre		Set 1	Set 2	Set 3	Set 4	Set 5	Set 6
Parametreler	MaxEpochs	120	120	100	110	125	130
	LayerLstm	100	110	120	120	125	130
	LayerBilstm	166	160	120	150	150	150
	dropoutL1	0,33	0,33	0,33	0,33	0,33	0,33
	dropoutL2	0,33	0,33	0,33	0,33	0,33	0,33
Sonuçlar	Eğitim Süresi	00:31:19	00:33:00	00:33:31	00:33:44	00:33:58	00:34:50
	Train Accuracy	93,67%	95,20%	93,52%	94,83%	95,30%	<b>99,71%</b>
	Test Accuracy	93,18%	99,83%	90,58%	<b>100,00%</b>	<b>100,00%</b>	<b>100,00%</b>


Tablo incelendiğinde eğitim süresi 31-35 dk. arasında değişmekte iken eğitim doğruluğu en düşük % 93,52 olduğu gözlemlenmiştir. Eğitim setinin daha önce hiç görmediği test verilerinde ise doğruluk oranı en düşük % 90,58 olmasına karşın üç parametre setinde %100 doğruluk oranı da yakalanmıştır. Eğitim doğruluk ortalaması % 95,37 iken test doğruluk oranı ortalaması

%97,27 olarak hesaplanmıştır. Her sette yanlış tahmin edilen veriler incelendiğinde bunların ağırlıklı olarak tuğla duvar, seramik döşeme ve laminat parke işlerinin olduğu görülmektedir.

Sonraki adımda yukarıdaki verilerin ışığında aşağıda belirtilen parametrelerle bir eğitim daha gerçekleştirilmiştir.

```
MaxEpochs = 125;
numHiddenUnits1 = 150;
numHiddenUnits2 = 50;
dropoutLayer1 = 0.33;
dropoutLayer2 = 0.33;
```

Bu nihai karar verilen parametreler ile eğitim 1 dakika 45 saniyede tamamlanmıştır. Eğitimde % 98,52 doğruluk oranına ulaşılırken test verilerinde % 100 doğruluk oranına ulaşılmıştır.



Şekil 4.45: Sensorlog ses verileri derin öğrenme ağı nihai eğitim süreci ekran görüntüsü

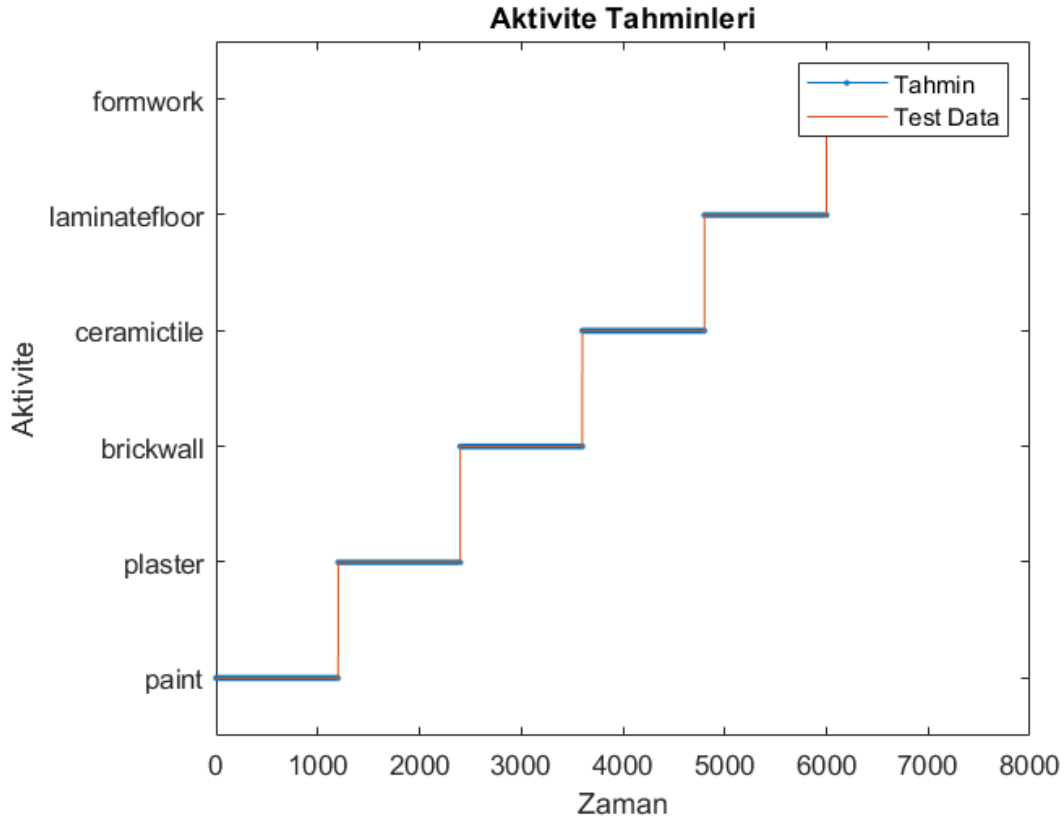
		Confusion Matrix							
Output Class	paint	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	plaster	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	brickwall	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	ceramictile	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	0 0.0%	100% 0.0%	
	laminat地板	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	0 0.0%	100% 0.0%	
	formwork	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1200 16.7%	100% 0.0%	
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	
		Target Class							
		paint	plaster	brickwall	ceramictile	laminat地板	formwork		

Şekil 4.46: Sensör konum verileri nihai eğitim hata matrisi ekran görüntüsü

Görüldüğü üzere eğitim sonucunda 144 sn. 7200 adet verinin tümü doğru olarak tahmin edilmiştir.

Tablo 4.24: Toplam test verisi ve tahmin değerleri çıktısı

	FarkTabloR	FarkTabloN
1	"Toplam Test Veri"	7200
2	"Toplam Test Sure"	144
3	"Dogru Tahmin Veri"	7200
4	"Dogru Tahmin Sure"	144
5	"Yanlis Tahmin Veri"	0
6	"Yanlis Tahmin Sure"	0



Şekil 4.47: Test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik

Sonraki aşamada aşağıdaki kod ile tahminlerin % oranı incelenmiştir.

```
WF=table(YTest1x',YPred1x',scr1(1,:)','scr1(2,:)','scr1(3,:)','scr1(4,:)','scr1(5,
:)',scr1(6,:)','...
'VariableNames',{'Test','Pred','Paint','Form','Brick','Ceramic','Laminate','Pl
aster'})
statarray = grpstats(WF,{'Pred'},{'min','max','mean'},...
'DataVars',{'Paint','Form','Brick','Ceramic','Laminate','Plaster'})
```

Tablo 4.25: İş bazında test verileri tahmin oranlarını gösterir tablo

Test	Pred	Paint	Form	Brick	Ceramic	Laminate	Plaster
paint	paint	0.8761	0.1019	0.0097	0.0019	0.0020	0.0083
paint	paint	0.9011	0.0820	0.0077	0.0014	0.0015	0.0064
paint	paint	0.9189	0.0669	0.0066	0.0011	0.0013	0.0053
paint	paint	0.9321	0.0558	0.0057	0.0008	0.0012	0.0044
paint	paint	0.9426	0.0473	0.0048	0.0006	0.0011	0.0035
paint	paint	0.9510	0.0409	0.0039	0.0005	0.0010	0.0027
paint	paint	0.9575	0.0360	0.0032	0.0004	0.0009	0.0021
paint	paint	0.9626	0.0321	0.0026	0.0003	0.0008	0.0016

paint	paint	0.9664	0.0293	0.0021	0.0002	0.0007	0.0013
paint	paint	0.9706	0.0260	0.0017	0.0002	0.0006	0.0010
paint	paint	0.9739	0.0233	0.0013	0.0001	0.0005	0.0008

Tablo 4.26: İş bazında tahminlerin yüzdesel dağılım özeti

Work	Min	Max	Ortalama
1 paint	<b>87,33%</b>	99,77%	<b>99,36%</b>
2 formwork	82,49%	99,92%	98,53%
3 brickwall	61,22%	99,49%	94,07%
4 ceramictile	84,78%	<b>99,97%</b>	98,22%
5 laminatefloor	75,07%	99,91%	97,11%
6 plaster	61,26%	99,93%	99,42%

Sonuçlara göre en düşük yani en kötü doğruluk tahmini % 61,22 ile tuğla duvar işinde görülmüştür. Toplamda 6 adet iş aktivitesi ile bu çalışmanın yapıldığı düşünüldüğünde en kötü sonucun bile aslında ne kadar başarılı bir tahmin olduğu görülmektedir. En başarılı tahmin ise % 99,36 ortalama ile boya işinde olmuştur. Tüm tahminlerin ortalaması %94 'ün üzerindedir.

Sonrasında test verisi kullanılarak çalışan ustanın hangi işte ne kadar süre çalıştığı aşağıdaki kod ile hesaplanmıştır.

```
WorkFreqTable=table(YPred1x(:));
%WorkFreqTable=cell2table(tabulate(YPred1x))
WorkFreq = groupsummary(WorkFreqTable, "Var1");
WorkFreq.WorkTime = WorkFreq.GroupCount/50
```

Şekil 4.48: İşçinin hangi işi ne kadar süre ile yaptığını gösterir program çıktısı

	Var1	GroupCount	WorkTime
1	paint	1200	24
2	plaster	1200	24
3	brickwall	1200	24
4	ceramictile	1200	24
5	laminatefloor	1200	24
6	formwork	1200	24

Sonuç olarak telefon le sensorlog programı ses verileri kullanılarak, oluşturulan derin öğrenme ağı ve parametreler ile, bir ustanın çalıştığı toplam 144 sn. süre içinde hangi işleri ne kadar süre ile yaptığı %100 doğruluk oranı ile tahmin edilmiştir.

#### 4.2.2. Ses Kayıt Verileri ile Aktivite Tahmini

Çalışmanın bu bölümünde eğitim için sensörden elde edilen veriler 10 sn. lik ( $10 \times 4,8 = 48$  adet veri) gruplara ayrılarak 309 adet grup kategorize edilmiştir. Çalışmada telefon mikrofonu tarafından kaydedilen ses verileri kullanılmıştır. Çalışmada eğitim için  $3 \times 48 \times 309 = 44.496$  adet veri kullanılmıştır. Yine her bir iş kalemi için yine 48 adet gruplar halinde test grupları oluşturulmuştur. Test verileri eğitim setinde kullanılmamıştır ve bu veriler eğitilmiş ağın ilk defa değerlendireceği verilerden oluşmaktadır. Araştırmada kullanılan 6 adet iş grubunun her birine ait 30 sn. lik test verisi kullanılmıştır. Bu noktadan hareketle testte  $6 \times 30 \times 4,8 \times 3 = 2.592$  adet veri kullanılmıştır. Herbir iş kalemi için kullanılan bu veriler etiketlenerek eğitim ağına aktarılmıştır.

Sonrasında bu veriler derin öğrenme eğitim ağına aktarılmıştır. Bu çalışmada derin öğrenme ağında farklı katmanlarda bir adet LSTM ve bir adet BiLSTM layer ve 2 adet dropout layer kullanılmıştır. Bu arada en etkin sonucu almak için öncelikle 6 farklı parametre kullanılarak eğitim sonuçları değerlendirilmiştir. Bu parametreler aşağıdaki tabloda gösterilmiştir.

Tablo 4.27: Sensör verileri için kullanılan hiperparametre setlerine ait değerler

Eğitim Parametre	Set 1	Set 2	Set 3	Set 4	Set 5	Set 6
MaxEpochs	300	330	360	320	330	360
LayerLstm	200	200	200	250	250	250
LayerBilstm	50	50	50	50	50	50
dropoutL1	0,33	0,33	0,33	0,33	0,33	0,33
dropoutL2	0,33	0,33	0,33	0,33	0,33	0,33

Yukarıdaki parametreler ile eğitim ağına ait eğitim sonrası sonuçları incelediğimizde;

Set 1 için eğitim süresi 00:08:51 olup, % 92,37 Eğitim doğruluk ve %89,12 test doğruluk oranına ulaşmıştır. Eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 1 Confusion Matrix**

<b>Output Class</b>	paint	128 14.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	plaster	16 1.9%	144 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90.0% 10.0%
	brickwall	0 0.0%	0 0.0%	101 11.7%	0 0.0%	15 1.7%	0 0.0%	87.1% 12.9%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	144 16.7%	20 2.3%	0 0.0%	87.8% 12.2%
	laminatelfloor	0 0.0%	0 0.0%	43 5.0%	0 0.0%	109 12.6%	0 0.0%	71.7% 28.3%
	formwork	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	144 16.7%	100% 0.0%
		88.9% 11.1%	100% 0.0%	70.1% 29.9%	100% 0.0%	75.7% 24.3%	100% 0.0%	89.1% 10.9%
	paint	plaster	brickwall	ceramictile	laminatelfloor	formwork		
<b>Target Class</b>								

Şekil 4.49: Hiperparametre Set1 için hata matrisi görüntüsü

Set 2 için eğitim süresi 00:09:32 olup, % 99,53 Eğitim doğruluk ve %100 test doğruluk oranına ulaşmıştır. Set 2 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 2 Confusion Matrix**

<b>Output Class</b>	paint	144 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	plaster	0 0.0%	144 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	144 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	144 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	144 16.7%	0 0.0%	100% 0.0%
	formwork	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	144 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	plaster	brickwall	ceramictile	laminatelfloor	formwork		
<b>Target Class</b>								

Şekil 4.50: Hiperparametre Set2 için hata matrisi görüntüsü

Set 3 için eğitim süresi 00:10:18 olup, % 98,94 Eğitim doğruluk ve % 100 test doğruluk oranına ulaşmıştır. Set 3 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.



**Training 3 Confusion Matrix**

<b>Output Class</b>	paint	144 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	plaster	0 0.0%	144 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	0 0.0%	144 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	0 0.0%	144 16.7%	0 0.0%	0 0.0%	100% 0.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	144 16.7%	0 0.0%	100% 0.0%
	formwork	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	144 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	paint	plaster	brickwall	ceramictile	laminatelfloor	formwork		
	<b>Target Class</b>							

Şekil 4.51: Hiperparametre Set3 için hata matrisi görüntüsü

Set 4 için eğitim süresi 00:10:40 olup, % 98,68 Eğitim doğruluk ve % 98,96 test doğruluk oranına ulaşmıştır. Set 4 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 4 Confusion Matrix**

<b>Output Class</b>	paint	144 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	plaster	0 0.0%	144 16.7%	3 0.3%	0 0.0%	0 0.0%	0 0.0%	98.0% 2.0%
	brickwall	0 0.0%	0 0.0%	135 15.6%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ceramictile	0 0.0%	0 0.0%	6 0.7%	144 16.7%	0 0.0%	0 0.0%	96.0% 4.0%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	144 16.7%	0 0.0%	100% 0.0%
	formwork	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	144 16.7%	100% 0.0%
		100% 0.0%	100% 0.0%	93.8% 6.3%	100% 0.0%	100% 0.0%	100% 0.0%	99.0% 1.0%
	paint	plaster	brickwall	ceramictile	laminatelfloor	formwork		
<b>Target Class</b>								

Şekil 4.52: Hiperparametre Set1 için hata matrisi görüntüsü

Set 5 için eğitim süresi 00:10:51 olup, % 99,24 Eğitim doğruluk ve % 95,72 test doğruluk oranına ulaşmıştır. Set 5 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 5 Confusion Matrix**

<b>Output Class</b>	paint	140 16.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	plaster	0 0.0%	111 12.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	brickwall	0 0.0%	3 0.3%	144 16.7%	0 0.0%	0 0.0%	0 0.0%	98.0% 2.0%
	ceramictile	4 0.5%	30 3.5%	0 0.0%	144 16.7%	0 0.0%	0 0.0%	80.9% 19.1%
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	144 16.7%	0 0.0%	100% 0.0%
	formwork	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	144 16.7%	100% 0.0%
		97.2% 2.8%	77.1% 22.9%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	95.7% 4.3%
	paint	plaster	brickwall	ceramictile	laminatelfloor	formwork		
<b>Target Class</b>								

Şekil 4.53: Hiperparametre Set5 için hata matrisi görüntüsü

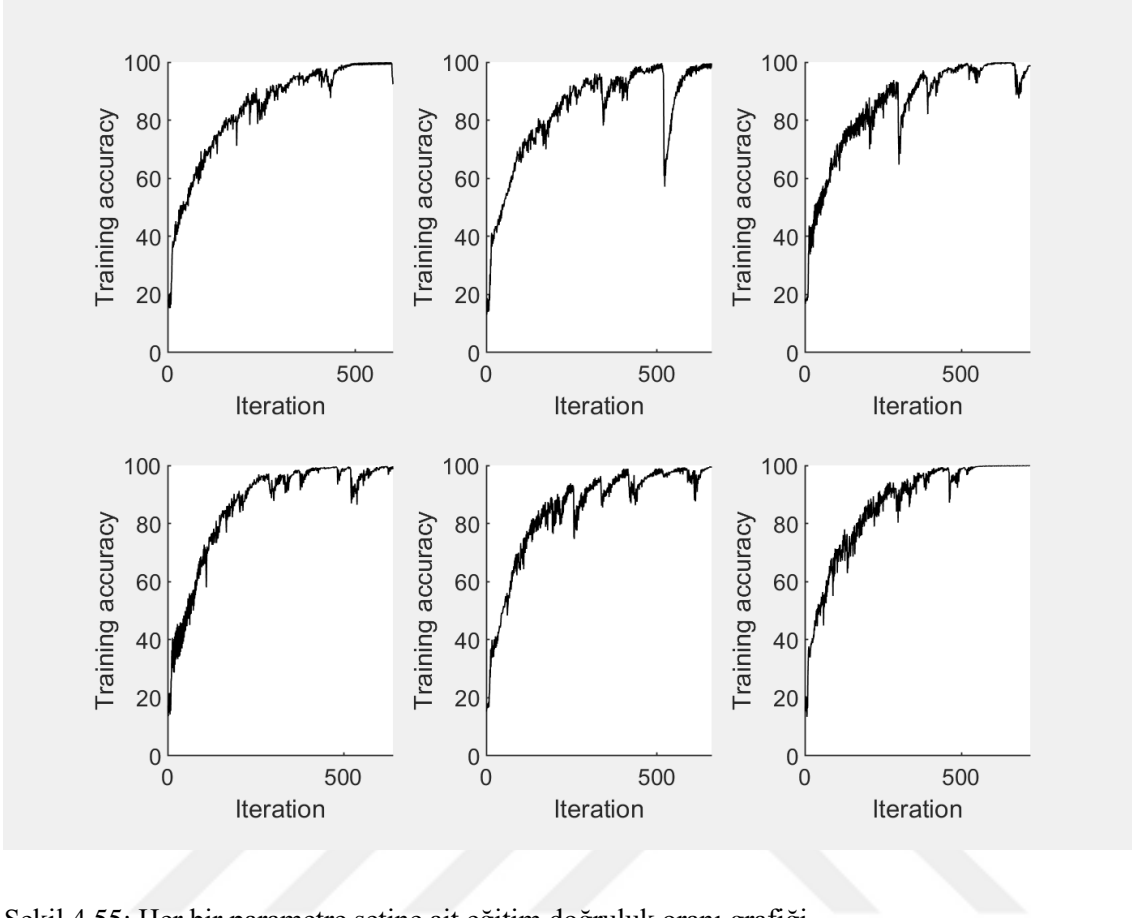
Set 6 için eğitim süresi 00:11:30 olup, % 99,92 Eğitim doğruluk ve %92,82 test doğruluk oranına ulaşmıştır. Set 6 parametreleri ile eğitim sonucu elde edilen test verilerine ilişkin karşılaştırma matrisi aşağıda sunulmuştur.

**Training 6 Confusion Matrix**

<b>Output Class</b>	paint	<b>123</b> 14.2%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	plaster	<b>21</b> 2.4%	<b>144</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>87.3%</b> 12.7%
	brickwall	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>103</b> 11.9%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	ceramictile	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>144</b> 16.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	laminatelfloor	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>144</b> 16.7%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	formwork	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>41</b> 4.7%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>144</b> 16.7%	<b>77.8%</b> 22.2%
		<b>85.4%</b> 14.6%	<b>100%</b> 0.0%	<b>71.5%</b> 28.5%	<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>92.8%</b> 7.2%
	paint	plaster	brickwall	ceramictile	laminatelfloor	formwork		
<b>Target Class</b>								

Şekil 4.54: Hiperparametre Set5 için hata matrisi görüntüsü

Her bir sete ilişkin iterasyon ve eğitim doğruluk grafiği aşağıda sunulmuştur.



Şekil 4.55: Her bir parametre setine ait eğitim doğruluk oranı grafiği  
Eğitim sonrası sonuçlara ilişkin özet tablo aşağıda sunulmuştur.

Tablo 4.28: Eğitim parametre setleri sonuç özeti

Eğitim Parametre		Set 1	Set 2	Set 3	Set 4	Set 5	Set 6
Parametreler	MaxEpochs	300	330	360	320	330	360
	LayerLstm	200	200	200	250	250	250
	LayerBilstm	50	50	50	50	50	50
	dropoutL1	0,33	0,33	0,33	0,33	0,33	0,33
	dropoutL2	0,33	0,33	0,33	0,33	0,33	0,33
Sonuçlar	Eğitim Süresi	00:08:51	00:09:32	00:10:18	00:10:40	00:10:51	00:11:29
	Train Accuracy	92,37%	99,53%	98,94%	98,68%	99,24%	<b>99,92%</b>
	Test Accuracy	89,12%	<b>100,00%</b>	<b>100,00%</b>	98,96%	95,72%	92,82%


Tablo incelendiğinde eğitim süresi 9-12 dk. arasında değişmekte iken eğitim doğruluğu en düşük % 92,37 olduğu gözlemlenmiştir. Eğitim setinin daha önce hiç görmediği test verilerinde ise doğruluk oranı en düşük % 89,12 olmasına karşın iki parametre setinde %100 doğruluk oranı da yakalanmıştır. Eğitim doğruluk ortalaması % 98,11 iken test doğruluk oranı ortalaması

%96,10 olarak hesaplanmıştır. Her sette yanlış tahmin edilen veriler incelendiğinde bunların ağırlıklı olarak tuğla duvar, siva ve boya işlerinin olduğu görülmektedir.

Sonraki adımda yukarıdaki verilerin ışığında aşağıda belirtilen parametrelerle bir eğitim daha gerçekleştirilmiştir.

```
MaxEpochs = 350;
numHiddenUnits1 = 200;
numHiddenUnits2 = 50;
dropoutL1 = 0.33;
dropoutL2 = 0.33;
```

Bu nihai karar verilen parametreler ile eğitim 1 dakika 1 saniyede tamamlanmıştır. Eğitimde % 99,97 doğruluk oranına ulaşılırken test verilerinde % 96,99 doğruluk oranına ulaşılmıştır.



Şekil 4.56: Ses verileri derin öğrenme ağı nihai eğitim ekran görüntüsü


		Confusion Matrix							
Output Class	paint	118 13.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	plaster	26 3.0%	144 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	84.7% 15.3%	
	brickwall	0 0.0%	0 0.0%	144 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	ceramictile	0 0.0%	0 0.0%	0 0.0%	144 16.7%	0 0.0%	0 0.0%	100% 0.0%	
	laminatelfloor	0 0.0%	0 0.0%	0 0.0%	0 0.0%	144 16.7%	0 0.0%	100% 0.0%	
	formwork	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	144 16.7%	100% 0.0%	
			81.9% 18.1%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	97.0% 3.0%
		Target Class							
		paint	plaster	brickwall	ceramictile	laminatelfloor	formwork		

Şekil 4.57: Ses verileri nihai eğitim hata matrisi ekran görüntüsü

Görüldüğü üzere eğitim sonucunda 180 sn. 864 adet verinin 174,58 sn. 868 adedi yanlış doğru olarak tahmin edilmiştir. 26 adet 5,41 sn. boya işi sıva işi olarak yanlış tahmin edilmiştir.

Tablo 4.29: Toplam test verisi ve tahmin değerleri çıktısı

	FarkTabloR	FarkTabloN
1	"Toplam Test Veri"	864.00
2	"Toplam Test Sure"	180.00
3	"Dogru Tahmin Veri"	838.00
4	"Dogru Tahmin Sure"	174.58
5	"Yanlis Tahmin Veri"	26.00
6	"Yanlis Tahmin Sure"	5.42



Şekil 4.58: Test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik

Sonraki aşamada aşağıdaki kod ile tahminlerin yüzde oranı incelenmiştir.

```
WF=table(YTest1x',YPred1x',scr1(1,:)','scr1(2,:)','scr1(3,:)','scr1(4,:)','scr1(5,
:)',scr1(6,:)','...
'VariableNames',{'Test','Pred','Paint','Form','Brick','Ceramic','Laminate','Pl
aster'})
statarray = grpstats(WF,{'Pred'},{'min','max','mean'},...
'DataVars',{'Paint','Form','Brick','Ceramic','Laminate','Plaster'})
```

Tablo 4.30: İş bazında test verileri tahmin oranlarını gösterir tablo

Test	Pred	Paint	Form	Brick	Ceramic	Laminate	Plaster
paint	paint	0.8942	0.0142	0.0058	0.0638	0.0108	0.0110
paint	paint	0.9184	0.0121	0.0043	0.0495	0.0076	0.0081
paint	paint	0.9417	0.0099	0.0028	0.0353	0.0048	0.0055
paint	paint	0.9618	0.0075	0.0017	0.0228	0.0028	0.0034
paint	paint	0.9766	0.0054	0.0009	0.0137	0.0015	0.0020
paint	paint	0.9858	0.0037	0.0004	0.0081	0.0008	0.0011
paint	paint	0.9906	0.0027	0.0002	0.0053	0.0005	0.0007
paint	paint	0.9927	0.0021	0.0001	0.0042	0.0003	0.0005



paint	paint	0.9933	0.0019	0.0001	0.0040	0.0003	0.0005
paint	paint	0.9928	0.0020	0.0001	0.0044	0.0003	0.0005
paint	paint	0.9914	0.0024	0.0001	0.0054	0.0003	0.0005

Tablo 4.31: İş bazında tahminlerin yüzdesel dağılım özeti

Work	Min	Max	Ortalama
1 paint	56,61%	99,98%	98,23%
2 formwork	49,39%	99,99%	95,30%
3 brickwall	86,54%	99,98%	99,47%
4 ceramictile	89,49%	99,97%	99,16%
5 laminatefloor	96,17%	<b>100,00%</b>	<b>99,86%</b>
6 plaster	<b>97,74%</b>	<b>100,00%</b>	99,83%

Sonuçlara göre en düşük yani en kötü doğruluk tahmini % 49,39 ile tuğla duvar işinde görülmüştür. En başarılı tahmin ise % 99,86 ortalama ile boya işinde olmuştur. Tüm tahminlerin ortalaması %95 'in üzerindedir.

Sonrasında test verisi kullanılarak çalışan ustanın hangi işte ne kadar süre çalıştığı aşağıdaki kod ile hesaplanmıştır.

```
WorkFreqTable=table(YPred1x(:));
%WorkFreqTable=cell2table(tabulate(YPred1x))
WorkFreq = groupsummary(WorkFreqTable, "Var1");
WorkFreq.WorkTime = WorkFreq.GroupCount/4.8
```

Tablo 4.32: İşçinin hangi işi ne kadar süre ile yaptığını gösterir program çıktısı

	Var1	GroupCount	WorkTime
1	paint	118	24.5833
2	plaster	170	35.4167
3	brickwall	144	30.0000
4	ceramictile	144	30.0000
5	laminatefloor	144	30.0000
6	formwork	144	30.0000

Sonuç olarak telefon ile kaydedilen ses verileri kullanılarak oluşturulan derin öğrenme ağı ve parametreler ile, bir ustanın çalıştığı toplam 180 sn. süre içinde hangi işleri ne kadar süre ile yaptığı %97 doğruluk oranı ile tahmin edilmiştir. Boya işinin 6 sn.lik kısmı sıva yapıyor olarak yanlış olarak tahmin edilmiştir.

## 5. TARTIŞMA VE SONUÇ

İşçi aktivitelerinin derin öğrenme ile otomatik tespiti isimli tez çalışması kapsamında sensör verileri ile aktivite tahmini olarak başlayan çalışma literatür taramalarında belirlenen çalışma yapılmamış alanlar ve çalışma sürecinde belirlenen gelişime açık alanlar eklenerek beş temel çalışma gerçekleştirilmiştir. Bu çalışmalardan üç adeti sensör verileri tabanlı iki adedi ise ses verileri tabanlıdır.

Bu kapsamda sadece ivme sensörü verilerinin derin öğrenme ağında eğitilmesi ile başlayan çalışma daha önce hiçbir çalışmada kullanımı görülmemeyen sensör ivme verileri yanında ilgili sensörün pozisyon verileride eklenerek geliştirilmiştir. Sensörlerle ilgili üçüncü bir çalışma olarak hem ivme hem konum verilerinin kombinasyonu kullanılmıştır.

Tez çalışması başlangıcında iki adet usta ile sıva ve boya işi için sağ ve sol el ivme sensörü verileri kullanılmıştır. Bu veriler ile derin öğrenme LSTM ağı kullanılarak geliştirilen algoritma ile çalışma yapılmıştır. Daha sonrasında farklı eğitim parametrelerinin sonuçlara etkisini görmek üzere bir algoritma kullanılmıştır. Bu çalışma ile farklı parametreler ile aynı anda 6 adet eğitim gerçekleştirilerek sonuçları incelenmiş ve başarı oranı en yüksek parametre seti ile nihai eğitim gerçekleştirilmiştir. Çalışma başlangıcında % 86 civarında olan doğruluk oranı eğitim parametre optimizasyonu ve BiLSTM katmanı ile derinlik artırılarak %100 doğruluk oranı yakalanmıştır.

Çalışmada farklı işçi ve iş aktivitelerindeki başarı oranını görmek üzere 2 olan işçi sayısı 5'e çıkarılmıştır. Bununla birlikte sadece sıva ve boya aktivitesine ilave olarak tuğla duvar, laminat parke, seramik döşeme, kalıp işide eklenerek aktivite sayısı 6 adete çıkarılmıştır. Bu süreçte yine sağ ve sol el sensörlere vücudun 11 noktasından veriler eklenmiştir.

Aşağıda sensör ile yapılan üç adet çalışmaya ilişkin nihai parametre setleri ile ulaşılan sonuçlar aşağıda sunulmuştur. Sonuçlara göre her üç çalışmada belirlenen parametre setleri ile % 100 doğruluk oranına ulaşmıştır. Burada dikkat çekici nokta bu kapsamda literatürde çalışma görülmemeyerek çalışmaya eklenen sensör konum verileri ile eğitimin sadece 41 sn. sürmesidir. Buda diğer çalışmalardan 1/8 oranında kısa bir süre olup, çok büyük veri setleri ile çalışmada bu farkın ciddi zaman kazancı sağlayacağı ve önem oluşturacağı değerlendirilmektedir.

Tablo 5.1: Sensör çalışmalarının karşılaştırmalı sonuçları

	<b>Eğitim Parametre</b>	<b>Sensör İvme</b>	<b>Sensör Konum</b>	<b>Sensör İvme+Konum</b>
Parametreler	MaxEpochs	27	30	33
	LayerLstm	66	66	99
	LayerBilstm	33	33	33
	dropoutL1	0,33	0,33	0,33
	dropoutL2	0,33	0,33	0,33
Sonuçlar	Eğitim Süresi	00:05:21	00:00:41	00:07:42
	Train Accuracy	99,68%	99,98%	99,91%
	Test Accuracy	100,00%	100,00%	100,00%

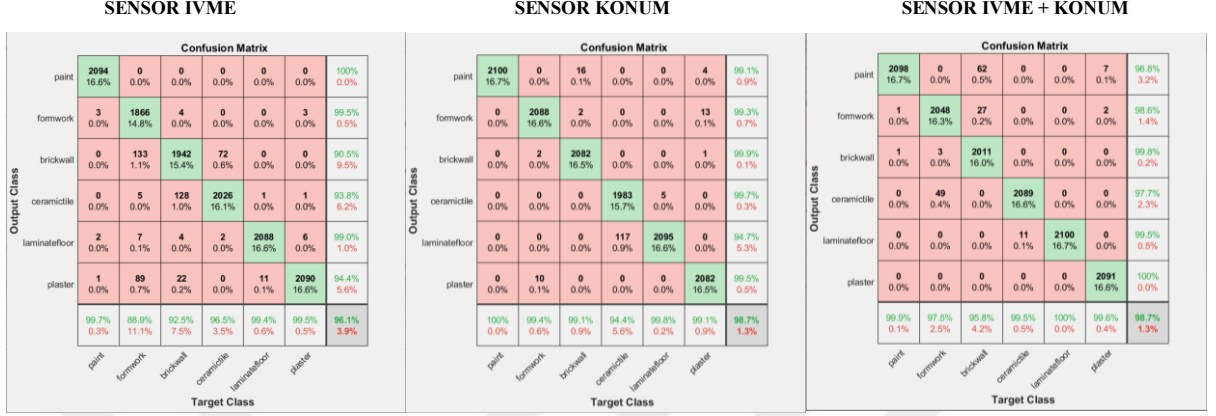
Sonuç kısmında aslında çalışmaya sonradan eklenen konum ve ivme+konum verilerinin gerçek manada etkisini görmek amacıyla bir çalışma daha yapılmıştır. Yukarıda anlatıldığı üzere derin ağ oluşturarak ve parametre optimizasyonu yaparak %100 doğruluk oranına ulaşılmıştır. Bu çalışmada her üç veri setinin de başarılı olduğu en yakın ortak parametre seti ile sadece LSTM katmanı ile ulaştığı sonuçlar analiz edilmiştir. Bu çalışmada sadece ivme verileri % 96,10 başarı oranı yakalarken konum ve ivme+konum verileri her ikisinde % 98,10 doğruluk oranını yakalamıştır. Seçilen parametre setleri ve sonuçları aşağıdaki tabloda sunulmuştur.

Tablo 5.2: Aynı eğitim parametleri ile tek LSTM katmanlı sensör çalışma sonuçları karşılaştırma


	<b>Eğitim Parametre</b>	<b>Sensör İvme</b>	<b>Sensör Konum</b>	<b>Sensör İvme+Konum</b>
Parametreler	MaxEpochs	33	33	33
	LayerLstm	99	99	99
	dropoutL1	0,20	0,20	0,20
Sonuçlar	Eğitim Süresi	00:00:48	00:00:42	00:00:42
	Train Accuracy	98,84%	95,96%	98,53%
	Test Accuracy	96,08%	98,71%	98,65%

Sonuçlardan görüldüğü üzere benzer parametre setinde konum verilerinin kullanıldığı çalışmalar daha başarılı sonuçlar sergilemiştir. İvme sensörü veri setinde eğitim doğruluk oranı daha yüksek iken test verilerine geldiğimizde konum verileri açık şekilde daha doğru sonuçlar vermiştir.

Aşağıda her üç çalışmaya ilişkin karşılaştırma matrisi ve grafiği yer almaktadır.



Şekil 5.1: Aynı parametre seti ile farklı sensör verileri hata matrisleri



Şekil 5.2: Aynı parametre seti ile test ve tahmin sonuçlarını zaman-aktivite bazında gösterir grafik

Bu karşılaştırma devamında her üç veri setine Bi-LSTM katmanı eklenerek ağ derinleştirilmiş ve yukarıdaki parametre setleriyle tümü % 100 doğruluk oranına ulaşmıştır. Bu noktadan hareketle benzer parametre setlerinde ivme sensörüne konum verilerinin eklenmesi test verilerinde doğruluk oranını artırmış ve daha doğru sonuçlar vermektedir.

Çalışma sırasında vücuda bağlı sensörler yanında ortam sesinden iş tahmini için çalışma ortamında iki noktadan iki farklı yöntemle ses verileri toplanmıştır. Böylece tez çalışması kapsamında sensörler ve ses toplam 215.780.548 adet veri toplanmıştır.

Ses verileri toplanması aşamasında, işin yapımı sırasında sabit iki noktadan cep telefonu mikrofonu ile ses verileri kaydedilmiştir. Bir tanesinde mikrofon ile normal ses kaydı diğerinde

ise Sersorlog yazılımı sesin dB cinsinden şiddeti ve ortalaması kayıt altına alınmıştır. Her iki farklı veri ile yapılan eğitim sonucu % 97-100 doğruluk oranı yakalanmıştır. Ortam ses kaydı ile yapılan çalışmada daha yoğun bir veri ön işleme süreci gerçekleştirmiştir. Sensorlog yazılımı ile kaydedilen çalışmada veriler direkt eğitime aktarılırken, 48Khz ses kaydı aktarılırken frekansın sistemde işlenebilmesi amacıyla veri setinin en yüksek, en düşük ve ortalama belirlenerek indirgenmesi için ciddi bilgisayar sistemi kaynağı kullanılmıştır. Ancak sonuç olarak her iki sistemde yüksek doğruluk oranını yakalamıştır.

Literatür taraması sonucu makine öğrenmesi veya derin öğrenme ile ilgili yapılan çalışmalarda ağırlıklı hazır veri setlerinin kullanıldığı, sadece sağlık alanında yapılan çalışmalarda ağırlıklı kendi verilerinin kullanıldığı, inşaat sektöründe konuya ilişkin yapılan kısıtlı çalışmalarda ise ağırlıklı makine öğrenmesi yöntemlerinin kullanıldığı görülmüştür. Yine bu çalışmaların hiçbirinde zaman serisi içinde yapılan iş tahmini yapılmamıştır olup sadece yapılan aktivitenin ne olduğu ile ilgili tahmin yapılmıştır.

Bu noktadan hareketle tez çalışması yapılan iş aktivitesi serisinde birim frekans zamanında tahmin ile diğer çalışmalardan farklılaşmıştır. Literatürde inşaat işçi aktivitesi tahmini ile ilgili tez kapsamında kullanılan LSTM yöntemi ile yapılan başka çalışma görülmemiştir. Bununla birlikte tüm vücut sensör verisi toplama, 6 ayı iş aktivitesini %100 doğruluk ile tespit, sensör verilerinin vücut konum verilerinin kullanılması, sensör verilerinde ivme ve vücut konum verilerinin birlikte kullanılması, aynı aktivite için ortamdan iki farklı ses kayıt yöntemi ile tahminlemesi bu tez çalışmasında taranan çalışmalardan farklı olarak kullanılan ilk yöntemdir.

Çalışmada ulaşılan başarılı sonuçların çok büyük inşaat projelerinde uygulanmasına yönelik geliştirilmesi gereken konular ise burada kablosuz olarak kullanılan sensörlerin kullanım sürelerinin ve kayıt sürelerinin artırılması önem arz etmektedir. Ayrıca her proje bütününde her işçiye sensör takılması hem işleyiş hem de kişisel verilerin işlenmesi açısından sakıncalar barındırmaktadır.

Bununla birlikte çalışmada ses verilerden başarılı sonuçlar elde edilmesine karşın çalışma ortamında yapılan işe ait sesi kirletici unsurlar yer almamaktadır. Çalışma ortamında çok farklı işlerin aynı anda yapıldığı bir ortamda ses ile iş aktivitesi tahmininde başarılı sonuçlara ulaşmak oldukça güç olacağı değerlendirilmektedir. Bu noktadan hareketle sensör verileri ile iş aktivitesi tahmininin inşaat sektöründe kullanım açısından daha doğru bir yöntem olduğu görülmektedir.

Tez çalışması zaman serisi tahmini, farklı sensör verileri kombinasyonu, ortam ses verileri, LSTM derin öğrenme ağı parametre optimizasyonu içermesi ile literatürdeki mevcut çalışmalara ciddi katkı sunması beklenmektedir. Ayrıca işçi aktivitelerinin %97-%100 aralığında doğrulukla otomatik olarak tahmini verimlilik, performans yönetimi, proje ilerleme kontrol gibi hususlarda destek sağlayacağı değerlendirilmektedir.



## 6. KAYNAKLAR

- A A.Raghav (2019) Bi-LSTM. What is a neural network? Just like our... | by Raghav Aggarwal | Medium. Available at: <https://medium.com/@raghavaggarwal0089/bi-lstm-bc3d68da8bd0> (Erişim: 07 Şubat 2021).
- Akhavian, R. ve Behzadan, A. H. (2016) “Smartphone-based construction workers’ activity recognition and classification”, *Automation in Construction*, 71(Part 2), ss. 198–209. doi: 10.1016/j.autcon.2016.08.015.
- Akhavian, R., Behzadan, A. H. ve Construction Endowed, C. (2018) COUPLING HUMAN ACTIVITY RECOGNITION AND WEARABLE SENSORS FOR DATA-DRIVEN CONSTRUCTION SIMULATION, Akhavian & Behzadan, pg. 1. *Journal of Information Technology in Construction (ITcon)*. Akhavian & Behzadan. Available at: <http://www.itcon.org/2018/1> (Erişim: 25 Ocak 2021).
- Almaslukh, B vd. (2017) An Effective Deep Autoencoder Approach for Online Smartphone-Based Human Activity Recognition Online Smartphone-Based Human Activity Recognition View project An Effective Deep Autoencoder Approach for Online Smartphone-Based Human Activity Recognition, *IJCSNS International Journal of Computer Science and Network Security*. Available at: <https://www.researchgate.net/publication/323019783> (Erişim: 04 Ocak 2021).
- Alsheikh, M. A. vd. (2016) “Deep activity recognition models with triaxial accelerometers”, içinde *AAAI Workshop - Technical Report*. AI Access Foundation, ss. 8–13. Available at: [www.aaai.org](http://www.aaai.org) (Erişim: 04 Ocak 2021).
- Bhattacharya, S. ve Lane, N. D. (2016) “From smart to deep: Robust activity recognition on smartwatches using deep learning”, içinde *2016 IEEE International Conference on Pervasive Computing and Communication Workshops, PerCom Workshops 2016*. doi: 10.1109/PERCOMW.2016.7457169.
- Bügler, M. vd. (2017) “Fusion of Photogrammetry and Video Analysis for Productivity Assessment of Earthwork Processes”, *Computer-Aided Civil and Infrastructure Engineering*, 32(2), ss. 107–123. doi: 10.1111/mice.12235.
- Bulling, A., Blanke, U. ve Schiele, B. (2014) “A tutorial on human activity recognition using body-worn inertial sensors”, *ACM Computing Surveys*, 46(3). doi: 10.1145/2499621.
- Cao, J., Huang, W., vd. (2017) “An enhance excavation equipments classification algorithm based on acoustic spectrum dynamic feature”, *Multidimensional Systems and Signal Processing*, 28(3), ss. 921–943. doi: 10.1007/s11045-015-0374-z.
- Cao, J., Zhao, T., vd. (2017) “Excavation equipment classification based on improved MFCC features and ELM”, *Neurocomputing*, 261, ss. 231–241. doi: 10.1016/j.neucom.2016.03.113.
- Cezar, G. (tarih yok) *Activity Recognition in Construction Sites Using 3D Accelerometer and Gyrometer*.

- Chavarriaga, R. vd. (2013) “The Opportunity challenge: A benchmark database for on-body sensor-based activity recognition”, *Pattern Recognition Letters*, 34(15), ss. 2033–2042. doi: 10.1016/j.patrec.2012.12.014.
- Chen, K. vd. (2018) “11 Deep Learning for Sensor-based Human Activity Recognition: Overview, Challenges and Opportunities”, *J. ACM*, 37(111), s. 38. doi: 10.1145/1122445.1122456.
- Chen, Y. vd. (2016) “LSTM Networks for Mobile Human Activity Recognition”, içinde. Atlantis Press, ss. 50–53. doi: 10.2991/icaita-16.2016.13.
- Chen, Y. ve Xue, Y. (2016) “A Deep Learning Approach to Human Activity Recognition Based on Single Accelerometer”, içinde *Proceedings - 2015 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2015*. Institute of Electrical and Electronics Engineers Inc., ss. 1488–1492. doi: 10.1109/SMC.2015.263.
- Cheng, C. F. vd. (2016) “Audio signal processing for activity recognition of construction heavy equipment”, içinde *ISARC 2016 - 33rd International Symposium on Automation and Robotics in Construction*. International Association for Automation and Robotics in Construction I.A.A.R.C), ss. 642–650. doi: 10.22260/isarc2016/0078.
- Cheng, C. F. vd. (2017) “Activity analysis of construction equipment using audio signals and support vector machines”, *Automation in Construction*, 81, ss. 240–253. doi: 10.1016/j.autcon.2017.06.005.
- Cheng, C. F. vd. (2019) “Evaluation of Software and Hardware Settings for Audio-Based Analysis of Construction Operations”, *International Journal of Civil Engineering*, 17(9), ss. 1469–1480. doi: 10.1007/s40999-019-00409-2.
- Cheng, W. Y. vd. (2017) “Human Activity Recognition from Sensor-Based Large-Scale Continuous Monitoring of Parkinson’s Disease Patients”, içinde *Proceedings - 2017 IEEE 2nd International Conference on Connected Health: Applications, Systems and Engineering Technologies, CHASE 2017*. Institute of Electrical and Electronics Engineers Inc., ss. 249–250. doi: 10.1109/CHASE.2017.87.
- Cho, K. vd. (2014) “Learning phrase representations using RNN encoder-decoder for statistical machine translation”, içinde *EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*. Association for Computational Linguistics (ACL), ss. 1724–1734. doi: 10.3115/v1/d14-1179.
- Complete Guide to Artificial Neural Network Concepts & Models (tarih yok). Available at: <https://missinglink.ai/guides/neural-network-concepts/complete-guide-artificial-neural-networks/> (Erişim: 30 Ocak 2021).
- Cook, D., Feuz, K. D. ve Krishnan, N. C. (2013) “Transfer learning for activity recognition: A survey”, *Knowledge and Information Systems*, 36(3), ss. 537–556. doi: 10.1007/s10115-013-0665-3.



- Cui, Z. vd. (2020) “Stacked Bidirectional and Unidirectional LSTM Recurrent Neural Network for Forecasting Network-wide Traffic State with Missing Values”, arXiv. Available at: <http://arxiv.org/abs/2005.11627> (Erişim: 07 Şubat 2021).
- Edel, M. ve Köppe, E. (2016) Binarized-BLSTM-RNN based Human Activity Recognition, 2016 International Conference on Indoor Positioning and Indoor Navigation, IPIN 2016. doi: 10.1109/IPIN.2016.7743581.
- Fang, H. ve Hu, C. (2014) “Recognizing human activity in smart home using deep learning algorithm”, içinde Proceedings of the 33rd Chinese Control Conference, CCC 2014. IEEE Computer Society, ss. 4716–4720. doi: 10.1109/ChiCC.2014.6895735.
- Gjoreski, H. vd. (2016) “Comparing Deep and Classical Machine Learning Methods for Human Activity Recognition using Wrist Accelerometer”, 25Th International Joint, (MI), ss. 1–7. Available at: <https://www.cc.gatech.edu/~alanwags/DLAI2016/2>. (Gjoreski+) Comparing Deep and Classical Machine Learning Methods for Human Activity Recognition using Wrist Accelerometer.pdf (Erişim: 05 Ocak 2021).
- Gong, J. ve Caldas, C. H. (2011) “An object recognition, tracking, and contextual reasoning-based video interpretation method for rapid productivity analysis of construction operations”, Automation in Construction, 20(8), ss. 1211–1226. doi: 10.1016/j.autcon.2011.05.005.
- Guan, Y. ve Plotz, T. (2017) “Ensembles of deep LSTM learners for activity recognition using wearables”, arXiv. Newcastle University, s. 11. doi: 10.1145/3090076.
- Ha, S. ve Choi, S. (2016) “Convolutional neural networks for human activity recognition using multiple accelerometer and gyroscope sensors”, içinde Proceedings of the International Joint Conference on Neural Networks. Institute of Electrical and Electronics Engineers Inc., ss. 381–388. doi: 10.1109/IJCNN.2016.7727224.
- Ha, S., Yun, J.-M. ve Choi, S. (2015) “Multi-modal Convolutional Neural Networks for Activity Recognition”, içinde 2015 IEEE International Conference on Systems, Man, and Cybernetics. IEEE, ss. 3017–3022. doi: 10.1109/SMC.2015.525.
- Hammerla, N. Y., Halloran, S. ve Plötz, T. (2016) “Deep, convolutional, and recurrent models for human activity recognition using wearables”, içinde IJCAI International Joint Conference on Artificial Intelligence. International Joint Conferences on Artificial Intelligence, ss. 1533–1540. Available at: <http://arxiv.org/abs/1604.08880> (Erişim: 05 Ocak 2021).
- Hannink, J. vd. (2017) “Sensor-Based Gait Parameter Extraction with Deep Convolutional Neural Networks”, IEEE Journal of Biomedical and Health Informatics, 21(1), ss. 85–93. doi: 10.1109/JBHI.2016.2636456.
- Hayashi, T. vd. (2015) “Daily activity recognition based on DNN using environmental sound and acceleration signals”, içinde 2015 23rd European Signal Processing Conference, EUSIPCO 2015, ss. 2306–2310. doi: 10.1109/EUSIPCO.2015.7362796.

- Hochreiter, S. ve Schmidhuber, J. (1997) “Long Short-Term Memory”, *Neural Computation*, 9(8), ss. 1735–1780. doi: 10.1162/neco.1997.9.8.1735.
- Hurwitz, J. ve Kirsch, D. (2018) *Machine Learning IBM Limited Edition*. Available at: <http://www.wiley.com/go/permissions>. (Erişim: 26 Ocak 2021).
- Hussain, Z., Sheng, M. ve Zhang, W. E. (2019) “Different approaches for human activity recognition- A survey”, arXiv.
- Inoue, M., Inoue, S. ve Nishida, T. (2018) “Deep recurrent neural network for mobile human activity recognition with high throughput”, *Artificial Life and Robotics*, 23(2), ss. 173–185. doi: 10.1007/s10015-017-0422-x.
- Introducing Deep Learning with MATLAB (2020).
- Introducing Machine Learning (2020).
- Introduction to LSTM Units in RNN | Pluralsight (2020). Available at: <https://www.pluralsight.com/guides/introduction-to-lstm-units-in-rnn> (Erişim: 05 Şubat 2021).
- Jiang, W. ve Yin, Z. (2015a) “Human activity recognition using wearable sensors by deep convolutional neural networks”, içinde *MM 2015 - Proceedings of the 2015 ACM Multimedia Conference*. Association for Computing Machinery, Inc, ss. 1307–1310. doi: 10.1145/2733373.2806333.
- Jiang, W. ve Yin, Z. (2015b) “Human activity recognition using wearable sensors by deep convolutional neural networks”, içinde *MM 2015 - Proceedings of the 2015 ACM Multimedia Conference*, ss. 1307–1310. doi: 10.1145/2733373.2806333.
- Khan, U. M. vd. (2017) “A deep learning framework using passive WiFi sensing for respiration monitoring”, içinde *2017 IEEE Global Communications Conference, GLOBECOM 2017 - Proceedings*. Institute of Electrical and Electronics Engineers Inc., ss. 1–6. doi: 10.1109/GLOCOM.2017.8255027.
- Kim, Hongjo vd. (2018) “Analyzing context and productivity of tunnel earthmoving processes using imaging and simulation”, *Automation in Construction*, 92, ss. 188–198. doi: 10.1016/j.autcon.2018.04.002.
- Kim, J. ve Chi, S. (2019) “Action recognition of earthmoving excavators based on sequential pattern analysis of visual features and operation cycles”, *Automation in Construction*, 104, ss. 255–264. doi: 10.1016/j.autcon.2019.03.025.
- Kim, K., Kim, Hongjo ve Kim, Hyoungkwan (2017) “Image-based construction hazard avoidance system using augmented reality in wearable device”, *Automation in Construction*, 83, ss. 390–403. doi: 10.1016/j.autcon.2017.06.014.
- Kim, Y. ve Li, Y. (2017) “Human Activity Classification with Transmission and Reflection Coefficients of On-Body Antennas Through Deep Convolutional Neural Networks”,

- IEEE Transactions on Antennas and Propagation, 65(5), ss. 2764–2768. doi: 10.1109/TAP.2017.2677918.
- Lane, N. D., Georgiev, P. ve Qendro, L. (2015) “DeepEar: Robust smartphone audio sensing in unconstrained acoustic environments using deep learning”, içinde UbiComp 2015 - Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing, ss. 283–294. doi: 10.1145/2750858.2804262.
- Lee, S. M., Yoon, S. M. ve Cho, H. (2017) “Human activity recognition from accelerometer data using Convolutional Neural Network”, içinde 2017 IEEE International Conference on Big Data and Smart Computing, BigComp 2017. Institute of Electrical and Electronics Engineers Inc., ss. 131–134. doi: 10.1109/BIGCOMP.2017.7881728.
- Li, X. vd. (2016) “Deep learning for RFID-based activity recognition”, içinde Proceedings of the 14th ACM Conference on Embedded Networked Sensor Systems, SenSys 2016, ss. 164–175. doi: 10.1145/2994551.2994569.
- Lim, T.-K. vd. (2016) “Artificial Neural Network–Based Slip-Trip Classifier Using Smart Sensor for Construction Workplace”, Journal of Construction Engineering and Management, 142(2), s. 04015065. doi: 10.1061/(ASCE)CO.1943-7862.0001049.
- Liu, C. vd. (2016) “Lasagna: Towards deep hierarchical understanding and searching over mobile sensing data”, içinde Proceedings of the Annual International Conference on Mobile Computing and Networking, MOBICOM, ss. 334–347. doi: 10.1145/2973750.2973752.
- Machine Learning: A Quick Introduction and Five Core Steps - Centric Consulting (tarih yok). Available at: <https://centricconsulting.com/blog/machine-learning-a-quick-introduction-and-five-core-steps/> (Erişim: 26 Ocak 2021).
- Memarzadeh, M., Golparvar-Fard, M. ve Niebles, J. C. (2013) “Automated 2D detection of construction equipment and workers from site video streams using histograms of oriented gradients and colors”, Automation in Construction, 32, ss. 24–37. doi: 10.1016/j.autcon.2012.12.002.
- Morales, F. J. O. ve Roggen, D. (2016) “Deep convolutional feature transfer across mobile activity recognition domains, sensor modalities and locations”, içinde International Symposium on Wearable Computers, Digest of Papers, ss. 92–99. doi: 10.1145/2971763.2971764.
- Mosavi, A., Ardabili, S. ve Várkonyi-Kóczy, A. R. (2020) “List of Deep Learning Models”, içinde Lecture Notes in Networks and Systems. Preprints, ss. 202–214. doi: 10.1007/978-3-030-36841-8\_20.
- Murad, A. ve Pyun, J. Y. (2017) “Deep recurrent neural networks for human activity recognition”, Sensors (Switzerland), 17(11). doi: 10.3390/s17112556.
- Nath, N. D., Chaspari, T. ve Behzadan, A. H. (2018) “Automated ergonomic risk monitoring using body-mounted sensors and machine learning”, Advanced Engineering Informatics, 38, ss. 514–526. doi: 10.1016/j.aei.2018.08.020.

- Ordóñez, F. J. ve Roggen, D. (2016a) “Deep convolutional and LSTM recurrent neural networks for multimodal wearable activity recognition”, *Sensors (Switzerland)*, 16(1). doi: 10.3390/s16010115.
- Ordóñez, F. J. ve Roggen, D. (2016b) “Deep convolutional and LSTM recurrent neural networks for multimodal wearable activity recognition”, *Sensors (Switzerland)*, 16(1). doi: 10.3390/s16010115.
- Pouyanfar, S. vd. (2018) “A survey on deep learning: Algorithms, techniques, and applications”, *ACM Computing Surveys*, s. 92. doi: 10.1145/3234150.
- Ravi, D. R. vd. (2017) “A Deep Learning Approach to on-Node Sensor Data Analytics for Mobile or Wearable Devices”, *IEEE JOURNAL OF BIOMEDICAL AND HEALTH INFORMATICS*, 21(1). doi: 10.1109/JBHI.2016.2633287.
- Ravi, D. vd. (2016) “Deep learning for human activity recognition: A resource efficient implementation on low-power devices”, içinde *BSN 2016 - 13th Annual Body Sensor Networks Conference*, ss. 71–76. doi: 10.1109/BSN.2016.7516235.
- Recurrent Neural Networks (RNN) Tutorial Using TensorFlow In Python - Edureka (2019). Available at: <https://www.edureka.co/blog/recurrent-neural-networks/> (Erişim: 03 Şubat 2021).
- Rezazadeh Azar, E. ve McCabe, B. (2012) “Automated Visual Recognition of Dump Trucks in Construction Videos”, *Journal of Computing in Civil Engineering*, 26(6), ss. 769–781. doi: 10.1061/(asce)cp.1943-5487.0000179.
- RNN, LSTM ve GRU modellerinin incelemesi | by Mc V. | Medium (tarih yok). Available at: <https://medium.com/@mcvarer/rnn-lstm-ve-gru-modellerinin-incelemesi-f59a73499edb> (Erişim: 03 Şubat 2021).
- Ronao, C. A. ve Cho, S. B. (2016) “Human activity recognition with smartphone sensors using deep learning neural networks”, *Expert Systems with Applications*, 59, ss. 235–244. doi: 10.1016/j.eswa.2016.04.032.
- Ryu, J. vd. (2019) “Automated Action Recognition Using an Accelerometer-Embedded Wristband-Type Activity Tracker”, *Journal of Construction Engineering and Management*, 145(1), s. 04018114. doi: 10.1061/(asce)co.1943-7862.0001579.
- Sabillon, C. A. vd. (2018) “A productivity forecasting system for construction cyclic operations using audio signals and a Bayesian approach”, içinde *Construction Research Congress 2018: Construction Information Technology - Selected Papers from the Construction Research Congress 2018*. American Society of Civil Engineers (ASCE), ss. 295–304. doi: 10.1061/9780784481264.029.
- Samuel, A. L. (1959) “Some Studies in Machine Learning Using the Game of Checkers”, *IBM Journal of Research and Development*, 3(3), ss. 210–229. doi: 10.1147/rd.33.0210.

- Sanwei, Y., Jiuwen, C. ve Jianzhong, W. (2015) “Acoustics recognition of construction equipments based on LPCC features and SVM”, içinde Chinese Control Conference, CCC. IEEE Computer Society, ss. 3987–3991. doi: 10.1109/ChiCC.2015.7260254.
- Schuster, M. ve Paliwal, K. K. (1997) Bidirectional Recurrent Neural Networks, IEEE TRANSACTIONS ON SIGNAL PROCESSING.
- Sherafat, B. vd. (2020) “Automated Methods for Activity Recognition of Construction Workers and Equipment: State-of-the-Art Review”, Journal of Construction Engineering and Management, 146(6), s. 03120002. doi: 10.1061/(asce)co.1943-7862.0001843.
- Shrestha, A. ve Mahmood, A. (2019) “Review of deep learning algorithms and architectures”, IEEE Access. Institute of Electrical and Electronics Engineers Inc., ss. 53040–53065. doi: 10.1109/ACCESS.2019.2912200.
- Siami-Namini, S., Tavakoli, N. ve Namin, A. S. (2019) “A Comparative Analysis of Forecasting Financial Time Series Using ARIMA, LSTM, and BiLSTM”, arXiv. Available at: <http://arxiv.org/abs/1911.09512> (Erişim: 07 Şubat 2021).
- Tezcan, O., Akcay, C. ve Gazioglu, B. (2019) “A Review on BIM and Information Technologies Research in the Construction Industry”, International Journal of Digital Innovation in the Built Environment (IJDIBE), 8(2), ss. 1–19. doi: 10.4018/IJDIBE.2019070101.
- Turing, A. M. (1950) “Computing machinery and intelligence”, içinde Machine Intelligence: Perspectives on the Computational Model. Taylor and Francis, ss. 1–28. doi: 10.1093/mind/lix.236.433.
- UCI Machine Learning Repository: OPPORTUNITY Activity Recognition Data Set (tarih yok). Available at: <https://archive.ics.uci.edu/ml/datasets/opportunity+activity+recognition> (Erişim: 12 Ocak 2021).
- UCI Machine Learning Repository: PAMAP2 Physical Activity Monitoring Data Set (tarih yok). Available at: <https://archive.ics.uci.edu/ml/datasets/PAMAP2+Physical+Activity+Monitoring> (Erişim: 12 Ocak 2021).
- UCI Machine Learning Repository: Smartphone Dataset for Human Activity Recognition (HAR) in Ambient Assisted Living (AAL) Data Set (tarih yok). Available at: [https://archive.ics.uci.edu/ml/datasets/Smartphone+Dataset+for+Human+Activity+Recognition+\(HAR\)+in+Ambient+Assisted+Living+\(AAL\)#](https://archive.ics.uci.edu/ml/datasets/Smartphone+Dataset+for+Human+Activity+Recognition+(HAR)+in+Ambient+Assisted+Living+(AAL)#) (Erişim: 12 Ocak 2021).
- Vepakomma, P. vd. (2015) A-Wristocracy: Deep learning on wrist-worn sensing for recognition of user complex activities, 2015 IEEE 12th International Conference on Wearable and Implantable Body Sensor Networks, BSN 2015. Institute of Electrical and Electronics Engineers Inc. doi: 10.1109/BSN.2015.7299406.
- Walse, K. H., Dharaskar, R. V. ve Thakare, V. M. (2016) “PCA based optimal ANN classifiers for human activity recognition using mobile sensors data”, içinde Smart Innovation,

Systems and Technologies. Springer Science and Business Media Deutschland GmbH, ss. 429–436. doi: 10.1007/978-3-319-30933-0\_43.

Wan, S. vd. (2020) “Deep Learning Models for Real-time Human Activity Recognition with Smartphones”, *Mobile Networks and Applications*, 25(2), ss. 743–755. doi: 10.1007/s11036-019-01445-x.

Wang, J. vd. (2019) “Deep learning for sensor-based activity recognition: A survey”, *Pattern Recognition Letters*, 119, ss. 3–11. doi: 10.1016/j.patrec.2018.02.010.

Wearnotch | Wearable 3D motion capture | Free apps | Mobile SDK | Template Code (2017). Available at: <https://wearnotch.com/> (Erişim: 12 Ocak 2021).

wiki:dataset [Human Activity/Context Recognition Datasets] (tarih yok). Available at: <http://har-dataset.org/doku.php?id=wiki:dataset> (Erişim: 12 Ocak 2021).

Yang, J. B. vd. (2015) “Deep convolutional neural networks on multichannel time series for human activity recognition”, içinde *IJCAI International Joint Conference on Artificial Intelligence*, ss. 3995–4001.

Yang, Z. vd. (2019) “Assessment of Construction Workers’ Labor Intensity Based on Wearable Smartphone System”, *Journal of Construction Engineering and Management*, 145(7), s. 04019039. doi: 10.1061/(asce)co.1943-7862.0001666.

Yao, S. vd. (2017) “DeepSense: A unified deep learning framework for time-series mobile sensing data processing”, içinde *26th International World Wide Web Conference, WWW 2017. International World Wide Web Conferences Steering Committee*, ss. 351–360. doi: 10.1145/3038912.3052577.

Zebin, T., Scully, P. J. ve Ozanyan, K. B. (2017) “Human activity recognition with inertial sensors using a deep learning approach”, içinde *Proceedings of IEEE Sensors*. doi: 10.1109/ICSENS.2016.7808590.

Zeng, M. vd. (2015) “Convolutional Neural Networks for human activity recognition using mobile sensors”, içinde *Proceedings of the 2014 6th International Conference on Mobile Computing, Applications and Services, MobiCASE 2014. Institute of Electrical and Electronics Engineers Inc.*, ss. 197–205. doi: 10.4108/icst.mobicase.2014.257786.

Zhang, L., Wu, X. ve Luo, D. (2016) “Recognizing human activities from raw accelerometer data using deep neural networks”, içinde *Proceedings - 2015 IEEE 14th International Conference on Machine Learning and Applications, ICMLA 2015. IEEE*, ss. 865–870. doi: 10.1109/ICMLA.2015.48.

Zhang, L., Wu, X. ve Luo, Di. (2015) “Human activity recognition with HMM-DNN model”, içinde *Proceedings of 2015 IEEE 14th International Conference on Cognitive Informatics and Cognitive Computing, ICCI\*CC 2015. Institute of Electrical and Electronics Engineers Inc.*, ss. 192–197. doi: 10.1109/ICCI-CC.2015.7259385.

Zhang, S. vd. (2017) “Human activity recognition using radial basis function neural network trained via a minimization of localized generalization error”, içinde *Lecture Notes in*

Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). Springer Verlag, ss. 498–507. doi: 10.1007/978-3-319-67585-5\_50.

Zhang, Y. vd. (2017) “Poster Abstract: CAR - A deep learning structure for concurrent activity recognition”, içinde Proceedings - 2017 16th ACM/IEEE International Conference on Information Processing in Sensor Networks, IPSN 2017, ss. 299–300. doi: 10.1145/3055031.3055058.



**7. EKLER**

