

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SERU ÜRETİM KONTROLÜ İÇİN GERÇEK ZAMANLI
GÖRÜNTÜ İŞLEME SİSTEMİ TASARIMI MODEL ÖNERİSİ

DOKTORA TEZİ

Merve ŞİŞÇİ

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Bilim Dalı

MAYIS 2024

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SERU ÜRETİM KONTROLÜ İÇİN GERÇEK ZAMANLI
GÖRÜNTÜ İŞLEME SİSTEMİ TASARIMI MODEL ÖNERİSİ

DOKTORA TEZİ

Merve ŞİŞÇİ

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Bilim Dalı

Tez Danışmanı: Prof. Dr. Orhan TORKUL

Ortak Danışman: Doç. Dr. İhsan Hakan SELVİ

MAYIS 2024

Merve ŐIŐCI tarafından hazırlanan ‘‘Seru Üretim Kontrolü İin Gerek Zamanlı Görüntü İŐleme Sistemi Tasarımı Model Önerisi’’ adlı tez alıŐması 15.05.2024 tarihinde aŐağıdaki jüri tarafından oy birliğı/oy okluğı ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliğı Anabilim Dalı **Endüstri Mühendisliğı** Bilim Dalı’nda Doktora tezi olarak kabul edilmiŐtir.

Tez Jürisi

Jüri BaŐkanı : **Unvan Adı SOYADI**
Sakarya Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI (DanıŐman)**
Sakarya Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI**
Sakarya Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI**
(Gerekliyse) Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI**
(Gerekliyse) Üniversitesi

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu çalışma T.C. Sakarya Üniversitesi Fen ve Mühendislik Bilimleri Etik Kurulu'ndan 18.01.2023 tarihinde onay alınarak hazırlanmıştır. Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “SERU ÜRETİM KONTROLÜ İÇİN GERÇEK ZAMANLI GÖRÜNTÜ İŞLEME SİSTEMİ TASARIMI MODEL ÖNERİSİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi'nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(15/03/2024).

Merve ŞİŞCİ

Anneme, babama, eşime ve çocuklarıma

TEŞEKKÜR

Bu tez çalışmasının planlanmasından sonuca ulaşmasına kadar geçen sürede sabırla ve özveriyle her türlü yardım ve desteğini esirgemeyen, doktora eğitimim boyunca her konuda değerli bilgi ve deneyimlerinden yararlanmamı sağlayan çok kıymetli danışman hocam Prof. Dr. Orhan TORKUL' a en derin minnettarlıklarımı sunarım.

Tez çalışması sürecinde büyük bir sabırla tüm sorularımı cevaplayan değerli ortak danışman hocam Doç Dr. İhsan Hakan SELVİ'ye minnet ve teşekkürlerimi sunarım.

Tez izleme jürimde yer alarak çalışmama yön veren ve destek olan değerli hocalarım Prof. Dr. İsmail Hakkı CEDİMOĞLU'na ve Dr. Öğr. Üyesi Mümtaz İPEK'e teşekkürü borç bilirim.

Çalışmamda sağlamış olduğu manevi desteklerden dolayı sevgili meslektaşım Öğr. Gör. Dr. Deniz DEMİRCİOĞLU DİREN'e ve tüm çalışma arkadaşlarıma teşekkürlerimi sunarım.

Bu zorlu süreçte her zaman en büyük destekçim ve yardımcım olan sevgili eşim Evren ŞİŞCİ'ye ve yaşam sevincim kızım Zeynep Ece ŞİŞCİ ve oğlum Cem Ata ŞİŞCİ'ye sonsuz teşekkür ederim. Ayrıca tüm hayatım boyunca en büyük desteği ve sevgiyi vererek hep yanımda olan annem Şükran ÖGE, babam Halil İbrahim ÖGE ve sevgili ağabeyim ve ablama çok teşekkür ederim.

Doktora eğitimim boyunca sağladıkları maddi destek sebebiyle Türkiye Bilimsel ve Teknoloji Araştırma kurumuna (TÜBİTAK) teşekkürlerimi iletirim.

Ayrıca bu çalışmanın maddi açıdan desteklenmesine olanak sağlayan Sakarya Üniversitesi Bilimsel Araştırma Projeleri (BAP) Komisyon Başkanlığına (Proje No: 2022-7-25-38) teşekkür ederim.

Çalışma sürecinde kullanılacak olan tüm verilerin paylaşımında destek olan Federal Elektrik Firması ve Üretim Şefi Ruhi ŞENOĞLU'na teşekkürlerimi sunarım.

Merve ŞİŞCİ

İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1. Tezin Amacı	4
1.2. Tezin Organizasyonu	5
2. LİTERATÜR ARAŞTIRMASI	7
2.1. Seru Üretim Sistemi	7
2.1.1. Seru üretim sistemi temel kavramları	7
2.1.2. Seru üretim sistemi ile ilgili yapılan çalışmalar	9
2.1.3. Seru üretim sistemi ile ilgili karşılaşılan zorluklar	18
2.2. Montaj Eylemlerinin Tanınması	22
2.3. Derin Öğrenme	32
2.4. Tezin Literatürdeki Çalışmalardan Farkı ve Literatüre Katkısı	37
3. ZEKİ SERU ÜRETİM SİSTEMİ MODELİ ÖNERİSİ	41
3.1. Zeki Seru Üretim Sistemi Modelinin Ana Bileşenleri	42
3.2. Zeki Seru Üretim Sistemi Mimarisi	45
3.2.1. Veri bağlantı katmanı	46
3.2.2. Veri toplama ve hazırlama katmanı	48
3.2.3. Derin öğrenme katmanı	50
3.2.4. Karşılaştırma ve seçim katmanı	52
3.2.5. Karar destek katmanı	53
3.3. Zeki Seru Üretim Sistemi Bileşenlerinin Detayları	54
3.3.1. Montaj işlemlerinin izlenmesi ve kontrolü	54
3.3.2. Montaj ortamının izlenmesi ve kontrolü	56
3.3.3. Ürün bileşenlerinin ve montaj araçlarının izlenmesi ve kontrolü	57
3.3.4. Kapasite ve performansın izlenmesi ve kontrolü	58
3.3.5. Depolama/envanterin izlenmesi ve kontrolü	59
3.3.6. Ergonomi ve güvenliğin izlenmesi ve kontrolü	61
4. MONTAJ EYLEMLERİNİN TANINMASI MODELİNİN GELİŞTİRİLMESİ	65
4.1. Verilerin Toplanması ve Düzenlenmesi	68
4.2. Poz Tahmini	70
4.3. Verilerin Hazırlanması	77
4.3.1. Verilerin etiketlenmesi	77
4.3.2. Veri setinin ayrılması	79

4.3.3. Veri arttırma	79
4.3.4. Segmentasyon.....	84
4.3.5. Kategorik deęişken dönüşümü	88
4.4. Derin Öğrenmeye Dayalı Sınıflandırma Modellerinin Geliştirilmesi	90
4.4.1. CNN modeli	91
4.4.2. LSTM modeli	93
4.4.3. GRU modeli	94
4.4.4. Bilstm modeli	95
4.4.5. Bigru modeli.....	96
4.4.6. CNN-LSTM modeli	97
4.4.7. CNN-GRU modeli.....	99
4.4.8. CNN-bilstm modeli.....	101
4.4.9. CNN-bigru modeli.....	103
4.4.10. CNN-bigru-CNN modeli.....	106
4.5. Montaj Eylemlerinin Tanınması Modellerinin Performanslarının Deęerlendirilmesi	107
4.5.1. Karmaşıklık matrisi	108
4.5.2. Doğruluk, kesinlik, duyarlılık ve f1-skor	109
4.6. Gerçek Zamanlı Uygulama.....	110
5. MONTAJ EYLEMLERİNİN TANINMASI MODELİNİN UYGULAMASI	113
5.1. Sistemin Tanıtımı	113
5.2. Sistem Gereksinimleri	115
5.3. Montaj Hattında Uygulama	116
5.3.1. Verilerin toplanması ve düzenlenmesi	117
5.3.2. Poz tahmini.....	119
5.3.3. Verilerin hazırlanması	119
5.3.3.1. Verilerin etiketlenmesi	119
5.3.3.2. Veri setinin ayrılması	120
5.3.3.3. Veri arttırma	120
5.3.3.4. Segmentasyon.....	121
5.3.3.5. Kategorik deęişken dönüşümü	122
5.3.4. Derin öğrenmeye dayalı sınıflandırma modellerinin geliştirilmesi.....	123
5.3.5. Montaj eylemlerinin tanınması modellerinin performanslarının deęerlendirilmesi.....	124
5.3.5.1. Veri arttırma yaklaşımının etkisinin deęerlendirilmesi.....	124
5.3.5.2. Poz tahmini yaklaşımlarının karşılaştırılması	128
5.3.5.3. Derin öğrenme modellerinin performanslarının karşılaştırılması ...	133
5.4. Seru Üretim Sisteminde Uygulama	137
5.4.1. Verilerin toplanması ve düzenlenmesi	137
5.4.2. Poz tahmini.....	138
5.4.3. Verilerin hazırlanması	139
5.4.4. Derin öğrenmeye dayalı sınıflandırma modellerinin geliştirilmesi.....	141
5.4.5. Montaj eylemi tanıma modellerinin performanslarının deęerlendirilmesi	141
5.4.5.1. Veri arttırma yaklaşımının etkisinin deęerlendirilmesi.....	142
5.4.5.2. Poz tahmini yaklaşımlarının karşılaştırılması	146
5.4.5.3. Derin öğrenme modellerinin performanslarının karşılaştırılması ...	150
5.5. Montaj Hattı ve Seru Üretim Sistemi Uygulama Sonuçlarının Karşılaştırılması	154

6. SONUÇ VE ÖNERİLER.....	157
KAYNAKLAR	161
EKLER	185
ÖZGEÇMİŞ.....	229

KISALTMALAR

AUGMENCON2	: Artırılmış epsilon kısıt yöntemi 2
BiGRU	: Çift Yönlü Geçitli Tekrarlayan Birim
BiLSTM	: Çift Yönlü Uzun Kısa Süreli Bellek
CNN	: Evrimsel Sinir Ağları
CRM	: Müşteri İlişkileri Yönetimi
DBN	: Derin İnanç Ağı
DNN	: Derin Sinir Ağı
ERP	: Kurumsal Kaynak Yönetimi
GRU	: Geçitli Tekrarlayan Birim
IMU	: Atalet ölçüm sistemi
IoT	: Nesnelerin İnterneti
JIT-OS	: Tam Zamanında Üretim organizasyon sistemi
LSTM	: Uzun Kısa Süreli Bellek
MAE	: Ortalama mutlak hata
MAPE	: Ortalama mutlak yüzde hata
MSE	: Hata kareleri ortalaması
MES	: Üretim Yürütme Sistemi
MZÖ	: Metot-Zaman Ölçümü
NN	: Sinir Ağı
NSGA2	: Baskın olmayan sıralama genetik algoritma 2
RBM	: Kısıtlı Boltzmann Makineleri
RMSE	: Hata kareleri ortalamasının kökü
R2	: Belirleme katsayısı
RNN	: Tekrarlayan Sinir Ağı
SAE	: Yığılmış Otomatik Kodlayıcı
SMOTE	: Synthetic Minority Oversampling Technique
SSD	: Single Shot Detector
sEMG	: Elektromiyografi
WOS	: Web of Science
2B	: 2 Boyutlu

3B : 3 Boyutlu

TABLO LİSTESİ

Sayfa

Tablo 2.1. Veritabanlarında arama süreci ayrıntıları.....	10
Tablo 4.1. Verilerin toplanması ve düzenlenmesi aşaması algoritması adımları.....	70
Tablo 4.2. MediaPipe Pose modeli tarafından elde edilen kilit noktaların isimleri. .	73
Tablo 4.3. MediaPipe Hands modeli tarafından elde edilen kilit noktaların isimleri.	74
Tablo 4.4. Elde edilen veri setlerinin özellikleri.	75
Tablo 4.5. Poz tahmininin uygulanması aşaması algoritması adımları.	76
Tablo 4.6. Verilerin etiketlenmesi aşaması algoritması adımları.	78
Tablo 4.7. Veri artırma aşaması algoritması adımları.	83
Tablo 4.8. Eğitim veri seti için segmentasyon aşaması algoritması adımları.	87
Tablo 4.9. Kategorik değişken dönüşümü aşaması algoritması adımları.	89
Tablo 4.10. Eğitim ve test veri setlerinin boyutu.	89
Tablo 4.11. 2 X 2 boyutlu karmaşıklık matrisinin bir gösterimi (Ortiz, 2014).	109
Tablo 4.12. Çok sınıflı sınıflandırma problemlerinde kullanılacak performans ölçütleri (Hossin ve Sulaiman, 2015).	110
Tablo 4.13. Montaj eylemlerinin tanınması modelinin gerçek zamanlı çalışma algoritması adımları.	111
Tablo 5.1. Üzerinde çalışılan montaj sürecine ait bilgiler.	114
Tablo 5.2. Montaj hattında istasyonlarda gerçekleştirilen görevler.	117
Tablo 5.3. Eğitim ve test veri setlerinin boyutları.	123
Tablo 5.4. V_{eller} veri seti üzerinde veri artırma yaklaşımı uygulanmadan eğitilen modellerin performansı.	134
Tablo 5.5. V_{eller} veri seti üzerinde veri artırma yaklaşımı uygulanarak eğitilen modellerin performansı.	135
Tablo 5.6. $V_{eller-vücut}$ veri seti üzerinde veri artırma yaklaşımı uygulanmadan eğitilen modellerin performansı.	136
Tablo 5.7. $V_{eller-vücut}$ veri seti üzerinde veri artırma yaklaşımı uygulanarak eğitilen modellerin performansı.	137
Tablo 5.8. Eğitim ve test veri setlerinin boyutları.	141
Tablo 5.9. V_{eller} veri seti üzerinde veri artırma yaklaşımı uygulanmadan eğitilen modellerin performansı.	151
Tablo 5.10. V_{eller} veri seti üzerinde veri artırma yaklaşımı uygulanarak eğitilen modellerin performansı.	152
Tablo 5.11. $V_{eller-vücut}$ veri seti üzerinde veri artırma yaklaşımı uygulanmadan eğitilen modellerin performansı.	153
Tablo 5.12. $V_{eller-vücut}$ veri seti üzerinde veri artırma yaklaşımı uygulanarak eğitilen modellerin performansı.	154

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Seru üretim sistemi çeşitleri (Liu ve ark, 2014).	8
Şekil 2.2. Seru Üretim Sistemi Üzerine yapılan çalışmaların yıllara göre dağılımı. .	10
Şekil 2.3. Derin öğrenme yöntemlerinin sınıflandırılması, Liu ve Lang (2019)'dan uyarlanmıştır.	33
Şekil 2.4. İleri beslemeli sinir ağının temel yapısı.....	34
Şekil 2.5. Evrimsel sinir ağının temel yapısı.....	34
Şekil 3.1. Zeki seru üretim sistemi.....	42
Şekil 3.2. Önerilen sistem mimarisi.....	46
Şekil 3.3. Veri bağlantısı bileşenleri.....	47
Şekil 3.4. Veri toplama ve hazırlama adımları.	49
Şekil 3.5. Derin öğrenme katmanı.	51
Şekil 3.6. Sistem katılımcıları için karar destek katmanı.	53
Şekil 3.7. Montaj İşlemlerinin izlenmesi ve kontrolü bileşeni diyagramı.	55
Şekil 3.8. Montaj ortamının izlenmesi ve kontrolü bileşeninin diyagramı.....	56
Şekil 3.9. Ürün bileşenlerinin ve montaj araçlarının izlenmesi ve kontrolü bileşeni diyagramı.....	58
Şekil 3.10. Kapasite ve performansın izlenmesi ve kontrolü bileşeni diyagramı.....	59
Şekil 3.11. Depolama /envanterin izlenmesi ve kontrolü bileşeninin diyagramı.	61
Şekil 3.12. Ergonomi ve güvenliğin izlenmesi ve kontrolü bileşeninin diyagramı..	62
Şekil 4.1. Montaj Eylemlerinin Tanınması Modeli.	65
Şekil 4.2. Montaj Eylemleri Tanınması Modelinin Çalışma Metodolojisi.....	68
Şekil 4.3. MediaPipe Holistic altyapısı ile elde edilebilen kilit noktalar (a) MediaPipe Pose (MediaPipe Github, 2020) (b) MediaPipe Hands (MediaPipe Github, 2019).	73
Şekil 4.4. Vtb, a örneğinin ve Etb, a etiketinin temsili görüntüsü.	76
Şekil 4.5. V_t veri setinin temsili görüntüsü.....	78
Şekil 4.6. VtE veri seti için veri arttırma işlemi.....	82
Şekil 4.7. CNN modeli ağ yapısı.	93
Şekil 4.8. LSTM modeli ağ yapısı.	94
Şekil 4.9. GRU modeli ağ yapısı.	95
Şekil 4.10. BiLSTM modeli ağ yapısı.	96
Şekil 4.11. BiGRU modeli ağ yapısı.....	97
Şekil 4.12. CNN-LSTM modeli ağ yapısı.	99
Şekil 4.13. CNN-GRU modeli ağ yapısı.....	101
Şekil 4.14. CNN-BiLSTM modeli ağ yapısı.....	103
Şekil 4.15. CNN-BiGRU modeli ağ yapısı.....	105
Şekil 4.16. CNN-BiGRU-CNN modeli ağ yapısı.	107
Şekil 5.1. Uygulamanın gerçekleştirildiği montaj hattının yerleşimi.	117
Şekil 5.2. Montaj hattı görüntü veri setindeki her bir montaj eylemi için ortalama çerçeve sayıları.....	118
Şekil 5.3. Montaj hattı veri setlerinde montaj eylemi sınıfına göre örnek sayıları. .	120

Şekil 5.4. Segmentasyon işlemi sonrası montaj hattı eğitim veri setinde montaj eylemi sınıfına göre örnek sayıları.....	122
Şekil 5.5. Segmentasyon işlemi sonrası montaj hattı test veri setinde montaj eylemi sınıfına göre örnek sayıları.....	122
Şekil 5.6. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre doğruluk performans ölçütü bazında karşılaştırılması.....	125
Şekil 5.7. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre kesinlik performans ölçütü bazında karşılaştırılması.....	126
Şekil 5.8. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre duyarlılık performans ölçütü bazında karşılaştırılması.....	127
Şekil 5.9. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre F1-Skor performans ölçütü bazında karşılaştırılması.....	128
Şekil 5.10. Modellerin poz tahmini yaklaşımlarına göre doğruluk performans ölçütü bazında karşılaştırılması.....	130
Şekil 5.11. Modellerin poz tahmini yaklaşımlarına göre kesinlik performans ölçütü bazında karşılaştırılması.....	131
Şekil 5.12. Modellerin poz tahmini yaklaşımlarına göre duyarlılık performans ölçütü bazında karşılaştırılması.....	132
Şekil 5.13. Modellerin poz tahmini yaklaşımlarına göre F1-Skor performans ölçütü bazında karşılaştırılması.....	133
Şekil 5.14. Uygulama için firmada kurulan yatai yerleşimi.....	137
Şekil 5.15. Seru üretim sistemi görüntü veri setindeki her bir montaj eylemi için ortalama çerçeve sayıları.....	138
Şekil 5.16. Seru üretim sistemi veri setlerinde montaj eylemi sınıfına göre örnek sayıları.....	139
Şekil 5.17. Segmentasyon işlemi sonrası seru üretim sistemi arttırılmış eğitim veri setlerinde montaj eylemi sınıfına göre örnek sayıları.....	140
Şekil 5.18. Segmentasyon işlemi sonrası seru üretim sistemi test veri setlerinde montaj eylemi sınıfına göre örnek sayıları.....	140
Şekil 5.19. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre doğruluk performans ölçütü bazında karşılaştırılması.....	143
Şekil 5.20. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre kesinlik performans ölçütü bazında karşılaştırılması.....	144
Şekil 5.21. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre duyarlılık performans ölçütü bazında karşılaştırılması.....	145
Şekil 5.22. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre F1-Skor performans ölçütü bazında karşılaştırılması.....	146
Şekil 5.23. Modellerin poz tahmini yaklaşımlarına göre doğruluk performans ölçütü bazında karşılaştırılması.....	147
Şekil 5.24. Modellerin poz tahmini yaklaşımlarına göre kesinlik performans ölçütü bazında karşılaştırılması.....	148
Şekil 5.25. Modellerin poz tahmini yaklaşımlarına göre duyarlılık performans ölçütü bazında karşılaştırılması.....	149
Şekil 5.26. Modellerin poz tahmini yaklaşımlarına göre F1-Skor performans ölçütü bazında karşılaştırılması.....	150

SERU ÜRETİM KONTROLÜ İÇİN GERÇEK ZAMANLI GÖRÜNTÜ İŞLEME SİSTEMİ TASARIMI MODEL ÖNERİSİ

ÖZET

Seru üretim sistemi atölye tipi üretimin esnekliği ile montaj hatlarının yüksek verimliliğini birleştiren yenilikçi bir montaj sistemidir. Bu üretim sistemi, ürün değişimlerine kolaylıkla uyum sağlamak, yarı mamul stoklarını ve gecikme süresini ortadan kaldırarak ürün israfını azaltmakta ve işletme maliyetlerini, gerekli işgücünü ve alanı azaltarak işletmelere rekabet avantajı sağlamaktadır. Bu avantajlarının yanı sıra, serü tipi üretimin bir ürünün montajı için gerekli tüm görevlerin çapraz eğitilmiş bir çalışan tarafından bir yatai(hücre)de tamamlanması gibi bir dezavantajı bulunmaktadır. Montaj hatlarında belirli görevler belirli istasyonlarda tamamlanırken, serü üretim sisteminde bahsedilen dezavantaj daha yüksek üretim hatası riskine neden olur. Bu çalışma, serü üretim sistemini Endüstri 4.0 teknolojileri ile bütünleştirerek bu hataların tespiti, önlenmesi ve en küçüklenmesini amaçlamaktadır. Bu amacı gerçekleştirmek için çalışmanın iki temel hedefi bulunmaktadır. İlk hedefi serü üretim sisteminde gerçek zamanlı bir kontrol sistemi modeli geliştirmektir. Bu hedefe yönelik, serü üretim sistemindeki proses ve kalite hatalarının önlenmesi için derin öğrenmeye dayalı gelişmiş analitikler kullanılarak üretim sürecinin çalışan, ortam, montaj araçları, ergonomi, depolama ve envanter gibi çoklu faktörlerinin izlenmesi, kontrol edilmesi ve gerektiğinde uyarı verilmesi için kavramsal bir model önerilmiştir. Önerilen Zeki Serü Üretim Sistemi Modeli, çalışana destek sağlamanın yanı sıra, sistem katılımcılarının üretim süreçleri hakkında veri elde etmelerine ve anlamalarına ve bu bilgilere dayanarak hızlı tepki vermelerine yardımcı olacaktır. İkinci temel hedefi, önerilen kavramsal modelin bünyesinde bulunan montaj eylemlerinin tanınması modelinin geliştirilmesidir. Bu hedefe yönelik ise, incelenen literatürde rastlanmayan iskelet tabanlı derin öğrenmeye dayalı Çift Yönlü Geçitli Tekrarlayan Birim (Bi-directional Gated Recurrent Unit - BiGRU) ve Evrimsel Sinir Ağları (Convolutional Neural Network - CNN) modelini içeren hibrit CNN-BiGRU-CNN montaj eylemlerinin tanınması modeli bu çalışmada geliştirilmiştir. Çalışmada, çalışan iskelet verilerinden yararlanılarak derin öğrenmeye dayalı sınıflandırıcı modellerin performanslarının iyileştirilmesi için aşağı örnekleme ve ölçeklemeye dayalı iki aşamalı bir veri arttırma yaklaşımı önerilmiştir. Montaj eylemlerinin sınıflandırılması için CNN, Uzun Kısa Süreli Bellek (Long Short Term Memory - LSTM), Geçitli Tekrarlayan Birim (Gated Recurrent Unit - GRU), Çift Yönlü Uzun Kısa Süreli Bellek (Bi-directional Long Short Term Memory - BiLSTM), BiGRU ve bu modellerin kombinasyonları sonucu oluşturulan hibrit modeller olmak üzere derin öğrenmeye dayalı on farklı tahmin modeli geliştirilmiştir. Geliştirilen modellerin her birinin etkinliklerini değerlendirmek için toplanan montaj süreci görüntüleri üzerinde analizler yapılarak bunların performansları karşılaştırılmıştır. Deneyler sonucunda, önerilen veri arttırma yaklaşımının tüm modellerin tahmin performansını iyileştirdiği görülmüştür. En iyi montaj eylemi sınıflandırma doğruluğuna önerilen hibrit CNN-BiGRU-CNN modeli ile ulaşılmıştır. Geliştirilen model ile montaj hattında %97, serü üretim sisteminde ise %96 tahmin doğruluk oranlarına ulaşıldığı belirlenmiştir.

Sınıflandırma algoritmalarının sınıf içi varyasyonlardaki farklılıklar azaldığında başarı oranlarının arttığı bilinmektedir. Bu çalışmada montaj hattında tahmin doğruluğunun daha yüksek olmasının nedeni, montaj hattında bulunan görevlerin serü üretim sistemine göre kendi içerisinde daha fazla benzerlik gösterebileceğidir.

A PROPOSAL OF REAL TIME IMAGE PROCESSING SYSTEM DESIGN MODEL FOR SERU PRODUCTION CONTROL

SUMMARY

As a result of technological developments, companies around the world have to design their production systems in a way that can meet customer demands, make profits and increase their competitiveness. Towards the end of Industry 1.0, the need for higher production volumes was addressed by Henry Ford's conveyor assembly line solution, which became the core innovation of Industry 2.0. Conveyor line systems have become widespread for use in the final assembly steps of mass production systems due to their high efficiency. Low product and labor costs and requiring less technical skills are among the other advantages of conveyor assembly line systems. As a result of the transformation of consumption patterns and the rapid development of digital technology, market demands in the Industry 3.0 process have shown an increasing trend towards high diversity and low volumes. Accordingly, product life cycles have shortened. Fluctuating and variable demand situations encountered due to such dynamic marketing conditions result in significant deterioration in the efficiency of conveyor assembly lines. Due to imbalances between stations on the assembly line, work-in-process are created, thus causing waste. Since it requires high capital costs, it becomes impossible to ensure the flexibility of the process in the production of new products.

With Industry 4.0, customization requirements such as shorter delivery times and reconfigurability and flexibility of production processes can not be met in traditional assembly lines. Assembly lines must be reconfigurable to accommodate product changes and changes in the product family of customized products. Companies and organizations can achieve competitive advantage to the extent they can respond to such changes. However, these changes cause difficulties in maintaining balance for traditional assembly lines. It becomes very important for manufacturers to meet the flexibility of their production systems in order to cope with the demands arising from fluctuations in wide range and volumes of product diversity. For this reason, production systems targeting Industry 4.0 must be supported by up-to-date technologies and have high flexibility and fast response features. In order to meet these, the necessity of developing new production systems has emerged.

Seru production system, which emerged in Japan in the 1990s as a result of increased product diversity and decreased demand for products, is an innovative assembly system and combines the flexibility of workshop type production with the high efficiency of assembly lines. This production system easily adapts to product changes, reduces product waste by eliminating semi-finished product stocks and delay time, and provides competitive advantage to businesses by reducing operating costs, required labor and space. In addition to these advantages, seru-type production has the disadvantage that all tasks required for the assembly of a product are completed in one yatai by a cross-trained worker. While certain tasks on assembly lines are completed

at specific stations, the mentioned disadvantage in seru production causes a higher risk of production errors.

This study aims to detect, prevent and eliminate these errors by integrating the seru production system with Industry 4.0 technologies. To achieve this aim, the study has two main objectives. Its first goal is to develop a real-time control system model in the seru production system. Towards this goal, a conceptual system model has been proposed to monitor and control multiple factors of the production process, such as workers, environment, assembly tools, ergonomics, storage and inventory, and to give warnings when necessary, in order to prevent process and quality errors in the seru production system.

The proposed Smart Seru Production System Model has six components. These components can be listed as follows:

- Monitoring and Controlling of Assembly Operations,
- Monitoring and Controlling of Assembly Environment,
- Monitoring and Controlling of Product Components and Assembly Tools,
- Monitoring and Controlling of Capacity and Performance,
- Monitoring and Controlling of Storage / Inventory,
- Monitoring and Controlling of Ergonomics and Safety.

A deep learning-based system architecture has been developed that supports the use of current technologies such as the Internet of Things (IoT) and augmented reality, which can be applied to each component to monitor and control the Seru system. Components are built in accordance with this architecture and are ensured to operate simultaneously. System components interact with each other. In addition, these components are planned to realize human activity recognition, object detection / tracking, time series prediction, posture analysis, indoor environment quality analysis, prediction / classification, delivery time prediction, worker performance evaluation implementations.

In addition to providing support to the worker, the proposed Smart Seru Production System Model will help system participants obtain and understand data about production processes and react quickly based on this information. With the system model, customer, supplier, production environment information network and interaction will be realized, worker performance and distribution system will be monitored in real time, and appropriate workforce and supply chain decisions will be supported.

The second main goal is to develop the recognition model of assembly actions included in the proposed conceptual model. In the assembly action recognition model, the basic task of determining the class of assembly actions that are complex and can be performed in different times will be carried out. For this task;

- worker pose data obtained from images collected with a single camera during the assembly process, and
- the deep learning-based assembly action recognition model developed in the study will be used.

For the above-mentioned deep learning-based assembly action recognition model, a skeleton-based hybrid CNN-BiGRU-CNN model is proposed. Assembly process video data was collected from the assembly line and seru production system to cover all assembly operations required to complete a product. MediaPipe Holistic

infrastructure, one of the pose estimation approaches, was used to obtain the worker skeleton data used in the model from RGB video images and provide it as input data to the model. With the use of MediaPipe (Hands), the V_{hands} data set was obtained by estimating only the key points on the hands. The $V_{\text{hands-body}}$ dataset was obtained by combining the predictions of key points on the hands and the body with the hybrid use of MediaPipe (Hands) and MediaPipe (Pose) pose estimation models. A two-stage data augmentation approach based on down-sampling and scaling is proposed to improve the performance of deep learning-based classifier models. Ten different models based on deep learning have been developed for the classification of assembly actions, including CNN, LSTM, GRU, BiLSTM, BiGRU and hybrid models generated as a result of combinations of these models.

The ten developed models were evaluated separately on the image data obtained from both the assembly line and seru production system, 80 experimental studies were carried out and compared in three aspects:

- 1- evaluation of the impact of the data augmentation approach: the impact of applying the data augmentation approach on classification prediction successes.
- 2- comparison of pose estimation approaches: Effect of V_{hands} dataset and $V_{\text{hands-body}}$ datasets on classification prediction success.
- 3- comparison of the performances of deep learning models: evaluation of the classification prediction success of ten classifier deep learning models.

When the effect of data augmentation approaches was evaluated, it was seen that there was an improvement in the determined performance criterion values of all assembly action recognition models developed on the V_{hands} data set and $V_{\text{hands-body}}$ data set, with the application of the data augmentation approach, both in the experiments on the assembly line and in the experiments in the seru production system. In this sense, it has been shown that the data augmentation approach developed is effective in classifying assembly actions.

As a result of the comparison of pose estimation approaches, it has been observed that almost all models in assembly line implementation have better classification power in terms of performance criteria determined when they are developed only on the $V_{\text{hands-body}}$ dataset. In the seru production system implementation, it was observed that most of the models showed better performance on the V_{hands} dataset in experiments where the data augmentation approach was not applied, but the models with the highest performance criterion scores were the models developed on the $V_{\text{hands-body}}$ dataset.

As a result of comparing deep learning models with experiments, it has been observed that the hybrid use of the CNN model with LSTM, GRU, BiLSTM and BiGRU models in both assembly line implementation and seru production system implementation generally gives better results in terms of performance criteria (accuracy, precision, recall and F1-Score) than when these models are used individually.

Considering all the experiments, better assembly action classification accuracy is observed by applying the data augmentation approach on the proposed hybrid CNN-BiGRU-CNN model $V_{\text{hands-body}}$ dataset. With the developed model, prediction accuracy rates of 97% in the assembly line and 96% in the mass production system were achieved.

1. GİRİŞ

İşletmelerin rakiplerine karşı rekabet avantajı elde etmelerinin en önemli yollarından biri, kaynaklarını en etkin ve verimli şekilde kullanarak yüksek kaliteye sahip ürünleri mümkün olan en düşük maliyetle üretmektir. Bu amaca ulaşmak için, işletmeler uzun yıllardır yüksek hacimli standart ürünleri verimli bir şekilde üretmek için ürün modeli değişiminin düşük olması nedeniyle, seri üretim ve montaj hatlarından yararlanmaktadırlar. Ancak teknolojinin gelişmesiyle birlikte akıllı telefon, kamera, bilgisayar gibi yüksek teknolojlü ürünlerdeki gelişmeler hızlanmış ve müşteri talep yapısını değiştirmiştir. Bu ürünlerin çeşitliliğinin artması, parti boyutunun ve ürün ömrünün azalmasına yol açmaktadır. Ürün karmaşıklık ve talebindeki bu tür değişiklikler nedeniyle, birçok imalat firması dinamik veya belirsiz koşullar olarak bilinen dalgalanmalarla karşı karşıya kalmaktadır. Ürün geliştirme, artan kişiselleştirme ve üretim sistemlerindeki değişikliklerden kaynaklanan ürün çeşitliliğinin yayılması nedeniyle birçok üretim ve montaj zorluğu ortaya çıkmıştır (ElMaraghy ve ElMaraghy, 2016). Bu koşullar altında montaj hatları gibi diğer geleneksel üretim yöntemleri pazar gereksinimlerini karşılayamaz duruma gelmektedir (Wang ve Tang, 2017). Verimli olmanın yanı sıra, üretim sistemlerinin artık esneklik ve uyarlabilirlik yeteneğine de sahip olmaları gerekmektedir.

Geleneksel montaj hatlarının eksikliklerinin giderilmesi için 1990'lı yıllardan itibaren serü üretim sistemi kullanılmaya başlanmıştır. Geleneksel montaj hattından farklı olarak, serü üretim sisteminde bir ürünün tamamının montajından sorumlu olan bir veya daha fazla küçük montaj ünitesi yapılandırılmıştır. Piyasa taleplerine ayak uydurmak için çalışanlar ve ürün grupları serü sistemine dinamik olarak atanabildiğinden, bir serü sistemi, geleneksel montaj hattı sistemine göre çok daha yüksek esnekliğe sahiptir. Ayrıca montaj hattının verimliliği en az beceriye sahip çalışan tarafından belirlenmektedir. Serü üretim sisteminde, çalışanın yeniden yapılandırılması, en az beceriye sahip çalışanın verimlilik üzerindeki etkisini önemli ölçüde azaltabilir. Serü üretim sisteminin montaj hattından daha esnek olmasının en önemli nedenlerinden biri, serü sistemindeki çalışanların birden fazla işi yürütebilen ve birden fazla ürünü işleyebilen çok-yetenekli operatörler olmasıdır. Serunun

esnekliđi, alıřanların belirli bir para/rn ailesini iřlettiđi hcresel retimden farklıdır. Seru sistemi, hareketli iř istasyonları, hafif montaj araları ve yksek yetenekli alıřanlar aracılıđıyla beklenmedik pazar deđiřikliklerine hızla yanıt verebilir. Buna ek olarak, seru sistemindeki alıřanlar daha fazla iř ve rn iřlemeye alıřabileceđinden, seru sistemi srekli olarak geliřtirilebilir (Li ve ark, 2017; Sun ve ark, 2016). Fakat avantajlarının yanı sıra, seru tipi retim dezavantajı, montaj hatlarında belirli grevler belirli istasyonlarda tamamlanırken, seru retiminde zellikle yataide bir rnn montajı iin gerekli tm grevlerin apraz-eđitimli bir alıřan tarafından bir yataide tamamlanmasıdır. Bu da, daha yksek retim hatası riskine neden olmaktadır. Bu nedenle, seru retim sistemi iin gerek zamanlı bir kontrol sistemi gereklidir.

Buna gre bu alıřmada, seru retim sisteminde retim srecini izlemek, kontrol etmek ve proses ve kalite hatalarının nlenmesi iin uyarı vermek amacıyla altı bileřenli bir zeki seru retim sistemi modeli nerilmiřtir. Diđer taraftan nesnelere interneti (IoT), derin đrenme ve makine đrenmesi, artırılmıř gereklik gibi yeni teknolojilerin seru retim sistemine entegre edilerek, mřteri, tedariki, retim ortamı bilgi ađının ve etkileřiminin gerekleřtirilmesi, alıřan performansının ve dađıtım sisteminin gerek zamanlı olarak izlenmesi ve uygun iřgc ve tedarik zinciri kararlarının ynetiminin desteklenmesi planlanmıřtır. Kavramsal model, insan aktivite tanıma, nesne tespiti/izleme, zaman serileri tahmini, duruř analizi, i ortam kalite analizi, tahmin/sınıflandırma, teslim sresi tahmini, alıřan performans deđerlendirmesini iermektedir. Seru retim ortamından geliřmekte olan farklı teknolojilerle birlikte toplanan byk miktarda veri, yapı ve tr bakımından farklılık gstermektedir. Toplanan bu byk verilerin geleneksel yntemler ile analiz edilmesi her zaman elveriřli olmamaktadır. Bunun iin daha geliřmiř tekniklerin kullanılması gerekmektedir. Derin đrenme, son yıllarda olduka popler olan ve karmařık yapılarıdaki birok problem iin olduka etkili ve kullanıřlı bir makine đrenme aracı olduđu kanıtlanan yapay zeka teknolojilerinden birisidir (Mohsen ve ark, 2018). Veri kullanılabilirliđindeki artıř ve gcl bilgi iřlem donanımının geliřmesiyle birlikte, yksek sınıflandırma performansına sahip, tepki sreleri hızlı ve dođrusal olmayan sınıflandırmada uygulanabilen derin đrenme yntemleri bilgisayarlı gr, konuřma iřleme ve dođal dil iřleme de dahil olmak zere birok alanda nemli bařarılar elde etmiřtir (Han ve ark, 2021; Iwana ve Uchida, 2021a; Le Guennec ve ark, 2016;

Ramachandra ve ark, 2021; Wen ve ark, 2020). Girdileri çıktılara dönüştüren bir model oluşturmak için, bir dizi algoritma kullanarak yüksek boyutlu eğitim verilerinin karmaşık ve doğrusal olmayan hiyerarşik özelliklerini çıkartır (Diro ve Chilamkurti, 2018). Bu sebeplerden dolayı önerilen kavramsal model derin öğrenmeye dayalı olarak geliştirilmiştir.

Farklı montaj modelleri ile çok çeşitli kişiselleştirilmiş ürünlerin bulunduğu montaj süreçlerinde bir montaj adımının gerçekleştirilmemesi, bir montaj hatasının hemen tespit edilmemesi sonraki montaj işlemlerinde hatalara, bunun sonucunda da zaman ve para kaybına neden olabilir ve ürün kalitesini olumsuz etkileyebilir (Chen ve ark, 2020a; Chen ve ark, 2020b). Bu dezavantajlara çözüm olarak montaj eylemlerinin gerçek zamanlı olarak tanınması sayesinde, insan hatalarının erken tespit edilerek zamanında düzeltilmesi ve çalışanların özel ihtiyaçlarına yönelik çalışmalarını kolaylaştırmayı sağlayabilir (Al-Amin ve ark, 2023). Seru üretim sistemine bu özelliklerin kazandırılması için bu çalışmada önerilen kavramsal model bünyesine Montaj Eylemlerinin Tanınması Modeli eklenmiştir. Model, sistemin dört bileşenine veri sağlamaktadır. Montaj eylemlerinin tanınması insan aktivite tanıma çalışmalarının bir alt kümesidir. Montaj süreçlerinin bilgisayarlı görme teknolojisi kullanarak izlenmesi ile, işletme maliyetlerinin ve kusurlu ürün oranının azaltılabileceği, ayrıca ürün üretim döngülerinin kısaltılabileceği bildirilmiştir (Chen ve ark, 2020b). Son zamanlarda araştırmalarda sıklıkla kullanılan ve insan davranışları hakkında fikir veren poz verileri, görüntü-tabanlı insan aktivite tanınması alanında başarılı sonuçlar elde edilmesini sağlamaktadır (Gupta ve ark, 2021). Bunun yanında, derin öğrenmenin birçok alanda gösterdiği başarılarından dolayı derin öğrenmeye dayalı birçok insan aktivite tanıma çalışması gerçekleştirilmiştir (Abbaspour ve ark, 2020; Mekruksavanich ve Jitpattanakul, 2022; Oluwalade ve ark, 2021; Yadav ve ark, 2021). Bu çalışmalarda derin öğrenme modellerinin tekli kullanımları yerine hibrit kullanımlarının tanıma başarısını arttırdığı değerlendirilmektedir (Abbaspour ve ark, 2020; Mutegeki ve Han, 2020). Derin öğrenme yöntemleri, sağlam ağ modellerinin eğitilmesi ve genelleme yeteneğinin artırılması için büyük örnek veri kümeleri gerektirdiğinden, eğitim verilerinin sayısının yüksek olmasının modelin performansı üzerinde oldukça büyük etkisi olmaktadır (Iwana ve Uchida, 2021b; Jeong ve ark, 2021; Ramachandra ve ark, 2021). Özellikle sınıflandırılmak istenen insan faaliyetlerinin sayısı arttığında, çok daha fazla sayıda eğitim verisi gerekecektir (Han

ve ark, 2021). Ancak, insan faaliyetlerine yönelik manuel olarak etiketlenen büyük ölçekli verilerin toplanması oldukça zaman alıcı ve zahmetli olduğu için etiketlenmiş gerçek dünya verileri sınırlı olmaktadır (Han ve ark, 2021; Jeong ve ark, 2021, Wang ve ark, 2022a; Wen ve ark, 2020). Yetersiz eğitim örnekleri içeren seyrek bir veri seti üzerinde eğitilen derin öğrenme modelleri, kendisine sağlanan sınırlı özellikler nedeniyle aşırı öğrenme (overfitting) sorununa yakalanabilir ve yetersiz sonuçlar üretebilir (Han ve ark, 2021; Nunez ve ark, 2018; Oh ve ark, 2020). Bu nedenlerden dolayı tez çalışması kapsamında, serü üretim sisteminde derin öğrenmeye dayalı poz tahmini, veri arttırma ve derin öğrenme zaman serisi sınıflandırma algoritmalarının hibrit kullanımı ile montaj eylemlerinin tanınması modeli önerilmektedir.

1.1. Tezin Amacı

Bu çalışmanın temel amacı serü üretim sisteminde gerçek zamanlı bir kontrol sistemi kavramsal modelinin geliştirilmesi ve bu kavramsal model bünyesinde bulunan montaj eylemlerinin daha yüksek doğrulukta tanınmasını sağlamaktır. Bu amaca ulaşmak için aşağıdaki alt amaçlar gerçekleştirilecektir:

- Zeki serü üretim sistemi modelinin ana bileşenlerinin tespit edilmesi,
- Zeki serü üretim sisteminin derin öğrenmeye dayalı mimarisinin geliştirilmesi,
- Zeki serü üretim sistemi bileşenlerinin çalışma yapısının tasarlanması.
- Montaj eylemlerinin tanınması modellerine girdi verilerinin poz tahmini ile sağlanması,
- Montaj eylemlerinin tanınması modellerinin tahmin başarı oranlarının arttırılması için yeni bir veri arttırma yaklaşımının geliştirilmesi,
- Montaj eylemlerinin tanınması için derin öğrenmeye dayalı hibrit CNN-BiGRU-CNN modelinin geliştirilerek değerlendirilmesi.

Geliştirilecek olan model yardımıyla montaj işlemlerinin sınıflandırılmasıyla, çalışanlar yanlış sırada bir işlem gerçekleştirdiklerinde hatalarını zamanında düzeltmeleri ve bir sonraki montaj işlemi hakkında bilgilendirilmeleri sağlanabilir. Bunların yanı sıra, çalışanların işbaşında eğitilmeleri sağlanarak beceri düzeyleri arttırılabilir. Aynı zamanda bu model sayesinde montaj işlemlerinin sürelerinin belirlenmesi ile çalışanların performansları gerçek zamanlı olarak izlenerek beceri düzeyleri anlık olarak belirlenebilir.

1.2. Tezin Organizasyonu

Bu tez çalışması aşağıda detayları verildiği gibi 6 ana bölümden oluşmaktadır. Bölüm 1'de çalışmanın amacı ve organizasyonu sunulmaktadır. Bölüm 2'de literatür araştırması ele alınarak serü üretim sistemi temelleri, yapılan çalışmalar ve serü üretim sisteminde karşılaşılan zorluklar açıklanmaktadır. Ayrıca montaj eylemlerinin tanınması üzerine yapılan çalışmaların detayları incelenerek, derin öğrenme yöntemlerinin tanıtımına ve tezin literatüre katkısına yer verilmektedir. Bölüm 3'te serü üretim sisteminin izlenmesi ve kontrol edilmesi için Zeki Serü Üretim Sistemi model önerisi gerçekleştirilmiştir. Bu bölümde modelin ana bileşenleri sunulmakta, zeki serü üretim sisteminin bileşenleri için önerilen mimari açıklanmakta ve bileşenlerin detayları incelenmektedir. Bölüm 4'te sistem bünyesinde bulunan montaj eylemlerinin tanınması modeli için önerilen metodolojinin aşamaları anlatılmaktadır. Bölüm 5'te ise Bölüm 4'te metodolojisi sunulan montaj eylemleri modelinin gerçek bir üretim ortamında montaj hattı ve serü üretim sistemi olmak üzere iki montaj sisteminde uygulaması sunulmaktadır. Son olarak, Bölüm 6'da tez çalışması kapsamında elde edilen sonuçlar, çalışmanın sınırlılıkları ve gelecek çalışmalar için öneriler ele alınmaktadır.

2. LİTERATÜR ARAŞTIRMASI

Bu bölümde serü üretim sistemi, montaj eylemlerinin tanınması konuları üzerinde literatür araştırmasına ve derin öğrenme yöntemleri hakkında bilgilere yer verilmektedir.


2.1. Serü Üretim Sistemi

Bu bölümde serü üretim sistemi ile ilgili temel kavramlara yer verilerek serü üretim sistemi ile ilgili yapılan çalışmalar incelenmiş ve sistem ile ilgili karşılaşılan zorluklar ele alınmıştır.

2.1.1. Serü üretim sistemi temel kavramları

Montaj hatları otomotiv endüstrisinde olduğu gibi büyük, karmaşık, seri olarak üretilen ürünlerin montajında yaygın olarak kullanılmış ve önemli başarılar elde edilmiştir. Fakat elektronik endüstrisi, kısa ürün ömrü, fazla ürün çeşitliliği ve dalgalı üretim hacimleri (kitle, yığın ve çok küçük hacimler) nedeniyle hızla değişen bir iş ortamındadır (Stecke ve ark, 2014). 1992'de Sony'de tasarlanan serü üretim sistemi, Japon elektronik endüstrisinde yaygın olarak kullanılan ve yeni bir üretim modeli olarak bilinen, montaj sistemi üzerine dayalı en başarılı üretim yeniliklerinden birisidir (Liu ve ark, 2010; Yu ve ark, 2016; Yu ve Tang, 2019; Zhang ve ark, 2017). Atölye tipi üretimin esnekliği ile konveyör montaj hatlarının verimliliğini önemli ölçüde birleştirmektedir (Liu ve ark, 2014). Serü, basit ekipmanlardan ve bir veya daha fazla ürünün montajı için atanmış bir veya daha fazla çalışandan oluşan montaj birimi olarak da adlandırılabilen bir üretim organizasyonudur (Yu ve ark, 2016). Serü üretim sisteminde, çalışan(lar) üretim sürecinin çoğunu veya tamamını tek başına tamamlayabilen çok yetenekli operatörler olmalıdır (Liu ve ark, 2014). Şekil 2.1'de gösterildiği gibi, bölümsel serü, dönel serü ve yatai, serü üretim sisteminin üç farklı çeşididir. Bölümsel serü, birden fazla çapraz eğitimli çalışan ile çalışan kısa bir montaj hattıdır. Montaj işlemleri farklı gruplara ayrılmıştır. Her görev grubu bir veya birkaç çalışan tarafından yürütülür. Bölümsel serünün aksine, dönel serülerde veya yatailerdeki çalışanlar tamamen çapraz eğitimlidir. Dönel serü, birkaç çalışan ile U

şeklinde bir düzende oluşturulur. Her çalışan, baştan sona eksiksiz bir ürünün tamamını monte eder. En küçük üretim organizasyonu olan yatai, tüm operasyonel ve yönetimsel görevleri tek bir çalışanın gerçekleştirdiği süper yetenekli bir serudur (Yu ve ark, 2013a; Yu ve ark, 2016; Sun ve ark, 2016). Yatai sayısının arttırılması birçok firmanın hedefidir (Stecke ve ark, 2014).



Şekil 2.1. Seru üretim sistemi çeşitleri (Liu ve ark, 2014).

Bir serunun üç temel prensibi vardır; kanketsu, majime, jiritsu. Kanketsu, bir ürünün montajının baştan sona yapılması için gerekli olan tüm görevlerin bir seru içerisinde gerçekleştirilmesi gerekliliğini ifade eder. Kanketsuyu başarabilmek için insan, ekipman, araçlar gibi gerekli tüm kaynakların bir seru içerisinde erişilebilir olması gerekmektedir. İşçilerin eğitimi için sürekli bir çapraz eğitim politikası geçerlidir. İşçiler çok veya tam yeteneklidir. Majime, tüm gereksiz hareketlerin azaltılması için tüm seru kaynaklarının birbirine yakın yerleştirilmesidir. Yakın ekipmanlar, sürekli malzeme akışını sağlarlar. Daha yakın çalışanlar daha fazla karşılıklı anlayışa, güvene ve bağlılığa sahip olabilir ve birbirlerine daha kolay yardım edebilirler. Bu, bilgi akışını geliştirir. Jiritsu, özerklik, öz-yönetim ve öğrenen organizasyon anlamına gelmektedir. Bir seru çalışanı, kendi tedarik zincirinde bağımsız bir organizasyondur. Seru üretiminde çalışanlar tüm görevlerden sorumlu oldukları için bu beceriyi kendi kendilerine sürekli olarak geliştirebilirler (Singh, 2017; Stecke ve ark, 2014; Yu ve Tang, 2019). İnsan merkezli bir üretim sistemi olan Seru, yalın organizasyonların ideali olarak kabul edilir. Yatai, birçok Japon yönetici tarafından en mükemmel insan/iş organizasyonu olarak kabul edilir (Stecke ve ark, 2014). Bu çalışma yatai üzerine odaklanmaktadır.

Bir seru sistemindeki serular hızlı bir şekilde yeniden yapılandırılabilir, yani kısa sürede sık sık oluşturulabilir, değiştirilebilir, sökülebilir ve yeniden kurulabilirler. Bu

yüzden serunun dalgalı hacimlerdeki ürünlerin üretimine Endüstri 3.0'ın taleplerini karşılayacak şekilde hızlı tepki vermesi, serü üretim sisteminin önemli bir performansdır (Sun ve ark, 2016). Diğer taraftan, Endüstri 4.0'ın gerektirdiği kitlesel özelleştirme, montaj hatlarından ziyade serü üretime olan ihtiyacı arttırmaktadır.


2.1.2. Serü üretim sistemi ile ilgili yapılan çalışmalar

Japonya'daki akademik araştırma ve üretim uygulamalarında, serü üretimi (Serü Seisan) oldukça ilgi görmektedir. Serü üretim ile ilgili ilk akademik makalenin Shinohara (1995) tarafından yazıldığı bilinmektedir (Liu ve ark, 2010; Zhang ve ark, 2017). Başlangıçta Asya dışında, serü üretim sistemi hakkında çok az kişi akademik ve pratik alanda çalışma yapmış olmasına rağmen (Zhang ve ark, 2017), son yıllarda serü üretim sistemi üzerinde geniş olarak çalışılan bir alan haline gelmiştir. Uluslararası alanda serü üretim sistemi ile ilgili yapılan çalışmaları incelemek amacıyla, Web of Science (WOS) ve Scopus veri tabanları taranmıştır. Tablo 2.1'de her bir veritabanı için arama sürecinde kullanılan alanlar ve arama ifadesi verilmektedir. Veritabanlarından veri elde etme süreci 4 Şubat 2023 tarihinde gerçekleştirilmiştir. WOS'tan elde edilen veriler 2008-2022 yılları arasında, Scopus'tan elde edilen veriler ise 1979-2023 yılları arasında yayınlanmış/yayınlanacak çalışmalardan oluşmaktadır. Arama sonucu WOS veritabanında 95, SCOPUS veritabanında ise 122 yayına ulaşılmıştır. Çalışmaların özetleri incelendiğinde WOS'ta elde edilen yayınlardan 2 tanesinin, Scopus'tan elde edilen yayınlardan 3 tanesinin serü üretim sistemi kapsamında olmadığı anlaşılmıştır. İki veritabanından elde edilen yayınlar karşılaştırıldığında, WOS'tan elde edilen ve konu ile ilgili olan sadece 7 yayının SCOPUS veritabanından elde edilen yayınlar arasında olmadığı belirlenmiştir. İki veritabanından elde edilen yayınlar birleştirilerek toplam 126 yayın elde edilmiştir.

Tablo 2.1. Veritabanlarında arama süreci ayrıntıları

Veritabanı	Arama Alanı	Arama İfadesi	Arama Sonucu Yayın Sayısı
Web of Science	“Topic” “Title” “Abstract” Author Keywords, Keyword Plus	OR "seru production" OR "seru production system" OR "line-seru conversion" OR "seru-system" OR "seru seisan" OR "seru system*" OR "seru loading" OR "seru manufacturing" OR "seru-type manufacturing" OR "line-cell conversion" OR ("seru" AND "production system") OR	95
Scopus	Article Abstract, Keywords	Title, "rotating seru" OR ("seru" AND "manufacturing cell")	122

İki veritabanından elde edilen seru üretim sistemi üzerine gerçekleştirilen 126 çalışmanın yıllara göre dağılımı Şekil 1’de verilmektedir. Şekil incelendiğinde, bu alanda yapılan çalışmaların 2008 yılında yayınlanmaya başladığı ve genel olarak bir artış izlediği özellikle 2017, 2021 ve 2022 yıllarında yayın sayılarının diğer yıllara göre ciddi bir artış gösterdiği görülmektedir. Seru Üretim Sistemi konusunun akademik alanda gittikçe ilgi çektiği bir gerçektir ve 2023 yılında da bu konu üzerine odaklanan çalışmaların 2022 yılındaki çalışma sayısını geçeceği öngörülmektedir.



Şekil 2.2. Seru Üretim Sistemi Üzerine yapılan çalışmaların yıllara göre dağılımı.

İki veritabanından elde edilen yayınlardan Seru üretimi ile ilgili ilk İngilizce makalenin Kaku ve ark. (2008a) tarafından yazıldığı görülmüştür. İki veritabanına ek olarak yapılan araştırmalar da göz önünde bulundurulduğunda, seru üretim sistemi konusu üzerindeki araştırmaların genellikle seru sisteminin avantajlarının ve uygulanmasının teorik açıdan analizi, hat-seru dönüşüm problemleri ve seru üretim sistemi uygulama kararları, hat-seru dönüşümü etkilerinin simülasyon yöntemi ile incelenmesi, çok yetenekli çalışan eğitim ve atama problemleri ve seru üretim sisteminin sürdürülebilirliği üzerinde gerçekleştirildiği söylenebilmektedir. Yin ve ark. (2008), Liu ve ark. (2010), Stecke ve ark. (2012), Liu ve ark. (2014), Stecke ve ark. (2014), Yin ve ark. (2017), Zhang ve ark. (2017) çalışmalarında, seru üretim sisteminin tanıtımı, temel özellikleri ve yönetsel mekanizmasının detayları verilmektedir. Seru kelimesi Japonca'da hücre anlamına gelmektedir ve bu nedenle hücresel üretim sistemi ile karıştırılmasına rağmen bu üretim modu ile arasında farklılıklar bulunmaktadır. Liu ve ark. (2010), Stecke ve ark. (2012), Villa ve Taurino (2013), Wang ve ark. (2013), Yin ve ark. (2018a), Yu ve Tang (2019) seru üretim sistemi ve geleneksel hücresel üretim sistemi arasındaki farklılıkları sunmaktadırlar. Diğer hücresel üretim sistemlerinin aksine seru üretim sistemi konveyör montaj hatlarından evrimleşmesiyle geliştirilmiştir ve seru üretim sisteminde hücreler talebi karşılayacak şekilde yapılandırılıp sökülebilmekte ve imalat yerine montaj, paketleme ve test işlemleri gerçekleştirilmektedir (de Treville ve ark, 2017). Seru üretim sistemi ile montaj hücreleri de çeşitli yönlerden farklılıklar göstermektedir. Yin ve ark. (2018a)'nin belirttiği üzere, montaj hücrelerinin birincil amacı ürün çeşitliliği ile baş edebilmek iken, serunun birincil amacı müşteri ihtiyaçlarına verimli ve esnek bir şekilde yanıt vermeyi sürdürmek, ikincil amacı ürün çeşitliliği ve hacmi ile başa çıkmaktır. Seru üretim sistemi Tam Zamanında Üretim organizasyon sistemi (JIT-OS) ile yönetilir ve kontrol edilirken, JIT-OS sistemi montaj hücrelerinde uygulanamaz çünkü montaj hücreleri seru gibi hızla yeniden yapılandırılmaz. En önemli farklardan birisi de seru sistemleri tamamen çapraz eğitilmiş çalışanların gerekliliğini savunurken (örneğin yatai), montaj hücrelerindeki çalışanlar kısmen çapraz eğitilidir.

Montaj hatlarının seru sistemine dönüşümü Kaku ve ark. (2009) tarafından hat-seru dönüşümü problemleri olarak adlandırılmıştır. Hat-seru dönüşümü problemleri ve seru üretim sistemi uygulama kararları seru oluşumu ve seru yüklemesi olmak üzere iki alt probleme ayrılmaktadır. Seru oluşumu probleminde, oluşturulacak seru sayısı

ile çalışanların serulara atanması ile ilgili kararlar verilirken, serü oluşumundan sonraki aşama olan serü yükleme probleminde ise, ürün yığınlarının serulara atanması ile ilgili kararlar verilir (Li ve ark, 2017). Bir çizelgeleme kuralı verilmediğinde ise, serü yükleme bir çizelgeleme (scheduling) problemine dönüşmektedir (Yu ve ark, 2013b). Literatürde bu problemler kapsamında toplam üretim süresi, toplam işgücü saati, tamamlanma zamanı, çalışan sayısı, toplam eğitim maliyeti, toplam akış zamanı, maksimum akış süresi, işgücü maliyeti, hizmet seviyesi, toplam gecikme, karbondioksit emisyonu, iş yükü dengesi, iş yükü dengesizliği, üretim miktarı, toplam boşa kalma süresi, serular arası sistem dengeleme veya serü içi sistem dengeleme, toplam ağırlıklı tamamlanma süresi, toplam net gelir gibi çeşitli amaçları optimize etmek (minimizasyon veya maksimizasyon) için tek amaçlı veya çok amaçlı optimizasyon modelleri geliştirmişlerdir. Kaku ve ark. (2008a), hat-hücre dönüşümü problemi üzerinde çalışarak toplam üretim süresi ve toplam iş gücü saatini en aza indirmeyi amaçlayan bir matematiksel model geliştirmişlerdir. Kaku ve ark. (2009), serü sistemi, montaj hattı ve hibrit serü sistemini (serü sistemi ve montaj hattının birleşimi) göz önünde bulundurarak toplam üretim süresi ve toplam işgücü saati amaçlarına sahip çok amaçlı bir optimizasyon modeli önermişlerdir. Yu ve ark. (2012), montaj hattını serü sistemine dönüştürmek için toplam üretim süresini ve toplam çalışma saatini en aza indirmeyi amaçlayan iki amaçlı bir matematiksel model geliştirmişlerdir. Modelin çözümü için baskın olmayan bir sıralama genetik algoritma kullanmışlardır. Liu ve ark. (2012), tamamlanma zamanının minimizasyonunu amaçlayan bir matematiksel model geliştirmişlerdir. Modeli elektronik sektörden gerçek endüstri verileri kullanarak değerlendirmişlerdir. Çalışmada önerilen modelin NP-zor olduğunu, büyük boyutlu problemler için etkili algoritmaların geliştirilmesi gerektiğini belirtmişlerdir. Yu ve ark. (2013a), hat-serü dönüşümünde çalışan sayısını ve toplam üretim süresini aynı anda azaltmak amacıyla çok amaçlı model önermişlerdir. Çok amaçlı hat-serü dönüşüm probleminin NP-zor olması nedeniyle küçük boyutlu problemlerde modelin Pareto-optimal çözümleri için geliştirilmiş kesin bir algoritma önermişlerdir. Yu ve ark. (2013b), montaj hattını serü sistemine dönüştürmek için iki amaçlı bir optimizasyon modelinde toplam üretim süresi ve toplam çalışma saatini göz önünde bulundurarak sistem performansını değerlendirmişlerdir. Yu ve ark. (2014), dönel serü ve yataiyi göz önünde bulunduran çok amaçlı bir optimizasyon modeli önermişlerdir. Bu modelde hat-serü dönüşümünde toplam üretim süresi ve toplam çalışma saati olmak üzere iki performans kriteri

optimize edilmiştir. Luo ve ark. (2016), çalışan-görev atamasını içeren tek dönemde serü yüklenme problemi için tamamlanma zamanını en aza indirmeyi amaçlayan bir optimizasyon modeli üzerinde çalışmışlardır. Modelin çözümü için sayılamayı kullanan sezgisel bir yöntem geliştirmişlerdir. Yu ve ark. (2016) 10 farklı çizelgeleme kuralının hat serü dönüşümünün performansı üzerindeki etkilerini toplam üretim süresi ve toplam çalışma saati kriterlerini kullanarak incelemişlerdir. Li ve ark. (2017), sistem değerlendirmesinde toplam üretim süresi ve toplam çalışma saatini göz önünde bulundurarak hat-serü dönüşüm sürecinde ortaya çıkan serü oluşumu ve serü yüklemesi olmak üzere iki alt problemi aynı anda çözmek için çok amaçlı işbirlikçi bir evrimsel yaklaşım önermişlerdir. Wang ve ark. (2017), stokastik talebi göz önünde bulundurarak, iş gücü maliyetini en küçükmek ve hizmet seviyesini en büyükmek amacıyla çok amaçlı bir matematiksel model geliştirmişlerdir. Yu ve ark. (2017), tamamlanma zamanını artırmadan çalışan sayısını azaltmaya yönelik bir hat-serü dönüşüm modeli oluşturmuşlardır. Küçük ve orta ölçekli problemler için iki kesin algoritma, büyük ölçekli problemler için büyük ölçekli örnekler için değişken uzunluklu kodlama sezgisel algoritmasını geliştirmişlerdir. Shao ve ark. (2017), tek bir ürünün farklı siparişleri için toplam akış zamanı ve toplam iş gücü maliyeti olmak üzere iki amaçlı bir hat-serü dönüşümü matematiksel modeli geliştirmişlerdir. Luo ve ark. (2017), belirsizlik altındaki serü yüklenme problemini ele alarak, tamamlanma zamanı ve toplam gecikme cezası maliyetini en aza indirmek için bulanık rassal iki amaçlı bir model oluşturmuşlardır. Yu ve ark. (2017) hat-hibrit serü dönüşüm problemi için tamamlanma zamanı ve toplam çalışma saati amaçlarına sahip çeşitli matematiksel modeller sunmuşlardır. Küçük ölçekli problemler için kesin algoritma, büyük ölçekli problemler için bir sezgisel algoritma geliştirmişlerdir. Lian ve ark. (2018), çalışanların beceri setleri ve yetkinlik seviyelerinde farklılıkların bulunduğu çalışan heterojenliğini göz önünde bulundurarak çalışan gruplama, hücre yüklenme ve görev atama problemini çözmek için serular arası ve çalışanlar arası iş yükü dengesini optimize etmeyi amaçlayan bir matematiksel model önermişlerdir. Wang ve Tang (2018), belirsiz talep altındaki serü oluşum problemini ele alarak, iş gücü maliyetini minimize etmek ve sistemin hizmet seviyesini maksimize etmek amacıyla bir optimizasyon modeli geliştirmişlerdir. Çok amaçlı optimizasyon modelini çözmek için örnek ortalama yaklaştırma ve baskın olmayan sıralama genetik algoritma 2 (NSGA2)'yi birleştirmişlerdir. Sun ve ark. (2019), tamamlanma zamanını en aza indirmek amacıyla serü oluşumu ve serü yüklemesi problemini eşzamanlı olarak

çözmek için bir işbirlikçi evrimsel algoritma geliştirmişlerdir. Bu algoritmada, serü oluşumu için genetik algoritma ve yerel arama kullanılırken, serü yükleme için arı kolonisi optimizasyonu kullanılmıştır. Wang ve ark. (2019a), serü üretim sisteminde sınırlı işleme kapasitesini ve parti bölmeyi göz önünde bulundurarak sipariş kabulü ve çizelgeleme problemi için toplam net geliri en büyükmek amacına sahip bir matematiksel model önermişlerdir. Yılmaz (2019), serü üretim sisteminde serular arası çalışan transferinin gerçekleştirilebildiği iş gücü çizelgeleme problemi için tamamlanma zamanı ve iş yükü dengesizliğini en aza indirmeyi amaçlayan iki amaçlı bir matematiksel modeli önermişlerdir. Küçük boyutlu problemlerde Pareto optimal çözümleri elde etmek için artırılmış epsilon kısıt yöntemi 2 (AUGMENCON2)'yi kullanmışlardır. Büyük boyutlu problemleri çözmek için ise NSGA2'yi kullanmışlardır. Sun ve ark. (2020), serü oluşum ve serü çizelgeleme problemlerini ele alarak, toplam gecikmeyi en küçükleyen bir matematiksel model oluşturmuşlardır. Küçük ölçekteki problemler için kesin bir algoritma ve büyük ölçekteki problemler için genetik algoritma, yerel arama ve arı kolonisi optimizasyonuna dayalı işbirlikçi evrimsel algoritma tasarlamışlardır. Ayough ve ark. (2020), dönel serularda hat-serü dönüşüm problemi ve iş rotasyonu çizelgeleme problemini birlikte ele alarak çalışan sayısını azaltarak maksimum akış süresini en aza indirmek için doğrusal olmayan bir tam sayılı programlama modeli oluşturmuşlardır. Modelin çözümü için etkili bir istilacı yabancı ot optimizasyonu (invasive weed optimization) algoritması tasarlamışlardır. Yılmaz (2020), serü üretimde işgücü çizelgeleme problemi için serular arası çalışan transferini göz önünde bulundurarak tamamlanma zamanını en aza indirmeyi amaçlayan bir matematiksel model önermişlerdir. Büyük boyutlu problemler için genetik algoritma tabanlı sezgisel yaklaşımlar geliştirmişlerdir. Zhang ve ark. (2020a), dengesiz serü üretim sistemlerinde parti bölme ve kurulum süresini göz önünde bulunduran çizelgeleme problemi için matematiksel model ve parçacık sürü optimizasyonundan yararlanan bir algoritma tasarlamıştır. Çalışkan ve ark. (2021), serü yükleme problemi üzerinde çalışarak maksimum tamamlanma zamanını en küçükmek amacıyla karışık tam sayılı matematiksel model ve açgözlü sezgisel yaklaşıma dayanan bir mat-sezgisel algoritma geliştirmişlerdir. Wu ve ark. (2021a), hibrit serü sistemi için serü oluşumu, serü çizelgeleme ve akış hattı çizelgeleme problemlerini ele almıştır. Problemlerin çözümü için tamamlanma zamanını en küçükmek amacıyla bir işbirlikçi evrimsel algoritma geliştirmişlerdir. Furugi ve Haliloğlu (2022), hat-serü dönüşümü ve serü

çizelgeleme problemlerini üzerinde çalışmışlar ve toplam gecikmeyi en küçüklemek amacıyla matematiksel bir model geliştirmişlerdir. Gai ve ark. (2022), serü yüklemesinde tamamlanma zamanını en aza indirmek için bir min-maks tam sayılı optimizasyon modeli ve kesin boyut küçültme algoritması geliştirmişlerdir. Li ve ark. (2022), serü oluşumu ve serü çizelgeleme problemlerini aynı anda ele alarak, tamamlanma zamanı ve toplam çalışma saatini minimize etmeyi amaçlayan bir evrimsel algoritması önermişlerdir. Liu ve ark. (2022), dönel serü üretim sisteminde çalışanların dönüşüm sırasını ve işlerin montaj sırasını belirlemek amacıyla toplam çalışma saati ve toplam akış zamanını minimize etmeyi amaçlayan dinamik çok amaçlı NSGA2 tabanlı bir memetik algoritma geliştirmişlerdir. Shan ve ark. (2022), hat-serü dönüşümünde tamamlanma zamanı ve çalışanların işgücü maliyeti ve eğitim maliyetlerinden kaynaklanan çalışan harcamalarını minimize etme amaçlarına sahip karma tam sayılı doğrusal programlama modeli geliştirmişlerdir. Modelin çözümü için benzetimli tavlama ile NSGA2 'yi birleştiren hibrit bir algoritma önermişlerdir. Zhang ve ark. (2022a), serü çizelgeleme problemi için toplam ağırlıklı tamamlanma zamanını maksimize eden bir tamsayılı programlama modeli oluşturmuşlardır. Modelin çözümü için dal-sınır algoritması ve sözde polinom dinamik programlama algoritmasından yararlanan bir sütun oluşturma tabanlı kesin çözüm yöntemi geliştirmişlerdir. Miao ve ark. (2022), hat-serü dönüşümünde parti bölme göz önünde bulundurulduğunda, tamamlanma zamanını en küçükleyen, serular arası sistem dengesini ve serü içi sistem dengesini en büyükmeyi amaçlayan bir matematiksel model geliştirmişlerdir. Zhang ve ark. (2022b), serü üretimde DeJong'un öğrenme etkisini ve parti bölmeyi göz önünde bulundurarak çizelgeleme problemi için toplam tamamlanma zamanını en aza indirmeyi amaçlayan bir doğrusal olmayan tamsayılı programlama modeli önermişlerdir. Küçük boyutlu problemlerin çözümü için dal ve sınır algoritmasından, büyük boyutlu problemler için yerel arama tabanlı hibrit genetik algoritmadan yararlanmışlardır.

Literatürde hat-serü dönüşümünün etkilerini gerçek hayattaki stokastik özellikleri de ele almak amacıyla simülasyon tekniği kullanarak montaj hatları ile karşılaştırmalı olarak inceleyen çalışmalar da mevcuttur. Bu çalışmalardan Kaku ve ark. (2008b) ürün çıktısı, operasyon süresi, ürün stok oranı ve kıtlık oranını, Prakash ve ark. (2017) hücrede yığın başına tamamlama süresi ve ortalama süreç içi stok seviyesini, Zwierzyński ve Ahmad (2018) ve daha sonra Zwierzyński (2019) üretim miktarı,

stoklar, süreçteki ortalama süre, süreçteki ortalama bekleme süresi, maliyet ve çalışan verimliliğini performans kriteri olarak değerlendirmişlerdir.

Çok yetenekli çalışanlar serü üretim sisteminin başarıyla uygulanması için vazgeçilmez ve en önemli bileşenlerinden birisidir (Liu ve ark, 2013). Serü üretim sisteminde çok yetenekli çalışanlar için çapraz eğitime yapılan yatırım miktarı diğer üretim yöntemlerinde olduğundan daha yüksektir (Singh, 2017). Serü üretim sisteminde çok yetenekli çalışanların eğitim ve atama problemine odaklanan bazı çalışmalar mevcuttur. Liu ve ark. (2013), bir serü sisteminde, toplam eğitim maliyetini en aza indirmeyi ve toplam işlem sürelerini dengelemeyi amaçlayan çok amaçlı bir matematiksel model ve toplam dokuz adımdan oluşan bir sezgisel algoritma geliştirmişlerdir. Manupati ve ark. (2015), işletmeler arasında bulunan birden çok yeniden yapılandırılmış serüde çalışanların eğitim ve görevlendirme problemi için toplam eğitim maliyetini, toplam işlem sürelerini en aza indirmek amacıyla tek amaçlı bir matematiksel model geliştirmişlerdir. Shao ve ark. (2016), stokastik siparişleri göz önünde bulundurarak, serü tasarımı ve çalışan ataması problemi için toplam akış süresini ve toplam eğitim maliyetlerini optimize etmek için doğrusal olmayan bir model oluşturmuşlardır. Ying ve Tsai (2017), serü üretim sisteminde çalışan eğitimi ve atama problemi için çok yetenekli çalışanların eğitim maliyetinden ve işlem sürelerinin denge maliyetinden kaynaklanan toplam maliyeti en aza indirmek amacıyla matematiksel bir model geliştirmişlerdir. Wu ve ark. (2018), bölümsel ve döne serü olmak üzere iki serü tipi için çapraz eğitimli çalışan ataması probleminde, çalışanların iş yükünü dengelemeyi ve serü üretiminin çıktı miktarını maksimize etmeyi amaçlayan matematiksel modeller oluşturmuşlardır. Deepthi ve ark. (2019a), toplam eğitim maliyetini en aza indirmek ve her bir çalışanın işlem süresini ve toplam üretim süresini kısaltmak amacıyla bir matematiksel model oluşturmuşlar ve uygun veya optimal işçi-serü atama planını ve görev-işçi planını belirlemek için sezgisel bir algoritma geliştirmişlerdir. Luo ve ark. (2021), çalışan atamasını içeren serü yükleme problemi için iki seviyeli bir programlama modeli önermişlerdir. Toplam boşta kalma süresini minimize etmeyi amaçlayan ve çalışan atamasının gerçekleştirildiği üst düzey modeli çözmek için benzetimli tavlama kullanmışlardır. Toplam tamamlanma zamanını minimize etmeyi amaçlayan ve ürün tahsisinin yapıldığı alt düzey modeli çözmek için ise genetik algoritmayı kullanmışlardır. Zeng ve ark. (2022), serü üretim sisteminde çok yetenekli çalışan atama problemi üzerinde çalışarak toplam çalışma

saatini ve iş yükü eşitsizliğini en küçüklemeyi amaçlayan bir karma tamsayı doğrusal olmayan programlama modeli önermişlerdir.

Bir firmanın verimliliği üretim verimliliğinin yanı sıra çevresel verimliliğini de içermektedir (Deepthi ve ark, 2019b). İmalat firmalarının daha rekabetçi olabilmek için enerji tüketimini ve ekonomiyi temel faktörler olarak kabul etmesi gerekmektedir (Liu ve ark, 2015). Hat-seru dönüşümü bazı önemli çevresel faydalar sağlayabilir (Zhang ve ark, 2017). Liu ve ark. (2015), serü üretim sisteminin sürdürülebilir performansı açısından ekonomik ve çevresel performansını ele alarak karbondioksit emisyonunu ve tamamlanma zamanını en aza indirgeyen bir matematiksel model geliştirmişlerdir. Modelin çözümü için NSGA2'ye dayanan bir algoritma geliştirmişlerdir. Kaku (2017), Japonya'daki serü ile ilgili yayınları incelemiş ve serü üretim sisteminin çevresel etkilerinin çok fazla ele alınmadığını belirtmiştir. Serü üretim sisteminin Canon'da uygulanmasıyla karbon dioksit emisyonunun önemli ölçüde azaldığını belirlemiştir. Zhang ve ark. (2017), kilit yardımcı teknolojilerin serü üretimi için sürdürülebilir performansın üç boyutu (çevresel, ekonomik ve sosyal performans) üzerindeki etkilerini doğrulayıcı faktör analizi ve yapısal eşitlik modeli yardımıyla araştırmışlardır. Serü üretim kapsamında sürdürülebilir performans için bir değerlendirme gösterge sistemi geliştirmişlerdir. Deepthi ve ark. (2019b), çalışanların toplam eğitim maliyetini, ürünlerin tamamlanma zamanını ve karbondioksit emisyonunu en aza indirmek amacıyla matematiksel bir model ve bir Güve Alev Optimizasyonu algoritması geliştirmişlerdir.

Uluslararası alanda İngilizce dilinde serü üretim sistemi üzerinde yapılan 3 adet yüksek lisans 1 adet doktora tezi çalışmasına rastlanmıştır. Khan (2017) çalışmasında, vinil pencere üretiminin tedarik zinciri tasarımı üzerine odaklanılmıştır. Üretim tesisi ve tedarikçi konumunu belirleme aynı anda ele alınarak, tedarik zincirinde tedarikçi seçimi maliyeti, üretim tesislerinde her bir hücre tipini açma maliyeti ve nakliye maliyetlerini azaltmayı hedefleyen ve iş gücü kullanılabilirliği kısıtını göz önünde bulunduran bir matematiksel model geliştirilmiştir. Gerekli imalat ve hücre sayıları ve kapasite stratejik ve taktik seviyesinde belirlenmiştir. Hat-serü dönüşümü gerçekleştirilerek operasyonel seviyede gerekli serü hücre sayıları belirlenmiştir. Klasik montaj hattı ve serü üretim sistemi senaryoları simülasyon çalışması aracılığıyla karşılaştırılarak analiz edilmiştir. Abdullah (2018) tez çalışmasında, montaj hattı ile serü üretim sistemini çalışanların becerilerini göz önünde bulundurarak

tek-ürün ve çok ürün durumu için karşılaştırmıştır. Çalışmada çalışanlar arasında farklı işler için beceri çeşitliliği yüksek olduğunda, montaj hattının daha iyi bir seçim olduğu, çok ürünlü durumlarda beceri dikkate alınmadığında ise serunun çoğu zaman daha iyi bir seçim olduğu tespit edilmiştir. Deepthi (2020) çalışmasında, serü üretim sistemi için çalışan atama problemi kapsamında eğitim maliyeti ve üretim süresini en aza indirmeyi amaçlayan matematiksel model geliştirmiştir. Modelin çözümü için iki aşamalı sezgisel yaklaşım geliştirmiştir. Knisley (2021)'in tez çalışmasında, çalışan beceri düzeyi dikkate alındığında belirli bir ortam için serü üretim sistemi ve montaj hattından en uygun montaj yönteminin ve eğitim yöntemi kombinasyonunun tespit edilmesi amaçlanmıştır. Çalışmada, eğitim yöntemi olarak iş başında eğitim, arttırılmış gerçeklik aracı ile eğitim ve kağıt el kitaplarının veya slayt gösterilerinin kullanıldığı eğitim olmak üzere üç seçenek mevcuttur. Montaj hattı için gerekli beceri seviyelerini ve çalışan atamalarını belirlemek için iki aşamalı bir model, serü için gerekli beceri seviyelerini belirlemek için ise doğrusal olmayan tek bir model kullanılmıştır.

Türkiye'de ise sadece bir adet yüksek lisans çalışmasına rastlanmıştır. Haliloğlu (2021) çalışmasında, hat-serü dönüşümü ve serü çizelgeleme problemini aynı anda ele alarak siparişlerin geç teslim etme sürelerini en küçükleme amacıyla bir matematiksel model geliştirmiştir. Modelin geçerliliği Yu ve ark. (2012) tarafından yayınlanan veri seti üzerinde gerçekleştirilmiştir.

2.1.3. Serü üretim sistemi ile ilgili karşılaşılan zorluklar

Literatür incelendiğinde, serü üretim sistemi için genellikle üretim planlama kararları üzerinde çalışıldığı görülmektedir. Serü üretim, ürün çeşitliliğine bağlı olarak farklı üretimlere kolayca adapte olabilme özelliği sayesinde artan ürün çeşitliliği ve dalgalı hacimler karşısında firmaların verimliliğini ve esnekliğini artıran bir üretim sistemidir. Ancak avantajlarının yanında dezavantajları da bulunmaktadır. Liu ve ark. (2010) ve Villa ve Taurino (2013) bu dezavantajları; serü boyutunda sonlu süreklilik, çok becerili çalışanlar için eğitime büyük yatırım gerekliliği, ekipman, montaj araçları ve nakliyyeyi içeren değişken üretim maliyetinin hafif artış göstermesi ve çalışanlar üzerinde oluşan yüksek baskı olarak sıralamışlardır. Bu dezavantajlardan özellikle ikisi sistemin işleyişi ve performansını önemli ölçüde etkilediğinden tez kapsamında ele alınmaktadır. Bunlar; çalışanların eğitimi ve eğitim maliyeti ile çalışanlar üzerindeki baskıdır.

Çalışanların eğitimi ve eğitim maliyeti: Seru üretim sisteminin temeli birden çok beceriye sahip çapraz eğitilmiş çalışana dayandığından, eğitim için büyük miktarda para ve zaman gereksinimi bulunmaktadır. Eğitim içeriğini çeşitli aparatların kullanımı ile farklı ürün tiplerinin çalışma yöntemleri oluşturmaktadır. Ürünlerdeki talep dalgalanmaları, eğitimin sürekliliğini gerektirmektedir. Bu nedenle uzun vadede eğitime yapılan yatırım da sürekli olmaktadır (Liu ve ark, 2010). Bu nedenlerden dolayı seru üretim sisteminde sürekli eğitimi destekleyecek ve eğitim maliyetlerini düşürecek gerçek zamanlı bir sistemin geliştirilmesi gerekmektedir. Kurushima (2017), düzensiz çalışan sayısının artmasıyla birlikte seru üretim sisteminin kullanımının Japonya'da artık tercih edilmediğini belirtmiştir. Seru üretimde yüksek yetenekli çalışanlara ihtiyaç duyulduğunun altını çizmiştir ve yeni deneyimsiz çalışanların ancak yeterince eğitilmesi durumunda verimliliğin artacağını vurgulamıştır. Montaj hatlarını seru üretim sistemine dönüştüren bazı firmalarda, çalışanlar yeterince eğitilmediğinden düzensiz çalışanlara hızlı geçiş nedeniyle üretimi sürdürmenin artık mümkün olmadığı belirtilmiştir. Yetersiz eğitilmiş yeni üyeler seru üretim sistemine girer girmez, sistem kararsız hale gelerek verimliliği büyük ölçüde azaltmıştır. Montaj hattına dönüş de yüksek maliyetler nedeniyle imkansız hale gelmiştir. Tüm çalışanlar yüksek vasıflı çalışanlar olmasa bile, iş dağılımını çalışanların yeteneklerine göre yapmak ve seru üretim süreçlerini ve sistem performansını etkileyen faktörleri yönetmek gerekmektedir. Literatür göz önünde bulundurulduğunda, çalışanların yeteneklerinin gerçek zamanlı belirlenmesinin ve iş dağılımlılarının bu yeteneklere göre yapılmasının seru üretim için büyük bir avantaj sağlayacağı, sürekli eğitimi destekleyen bir sistemin geliştirilmesinin de eğitim maliyetlerini önemli ölçüde düşüreceği değerlendirilmektedir.

Çalışanlar üzerindeki baskı: Seru üretim sistemi Jiritsu prensibinin getirdiği özerklik, öz-yönetim ve sürekli gelişim gerekliliği özelliklerini barındırmaktadır. Noguchi (2003)'nin belirttiği gibi, seru üretim sistemindeki çalışanların gelişimlerini destekleyebilmek için çeşitli eğitim kurslarına katılmaları gerekmektedir. Çalışanlar daha fazla bilgiye ulaşmak ve beceri kazanmak için çok fazla zaman ve enerji harcamakta, ayrıca üretimin yanı sıra kalite kontrolünden de sorumlu olmaktadır. Bunların yanında başkalarıyla çalışırken kişilerarası sorunlarla ilgilenmektedirler. Bu nedenle çalışanlar üzerindeki baskı ve yorgunluk, seru üretim sisteminde konveyör hattına göre daha fazla hissedilmektedir. Bu da bazı çalışanların seru üretim sistemine

geçiş konusunda direnç göstermesine ve dolayısıyla çeşitli yönetsel sorunlara neden olmaktadır (Liu ve ark, 2010). Tabata (2017)'ya göre ise, serü üretim sistemindeki en büyük sorun çalışan motivasyonu nedeniyle verimliliğin düşmesi olasılığıdır. Konveyör üretiminden farklı olarak serü üretim sisteminde kalp pili olarak da isimlendirilen konveyör hızı bulunmamaktadır. Dolayısıyla, üretkenlik, çalışanın bilincine ve fiziksel durumuna bağlı olarak iyi veya kötü olabilmektedir. Yazara göre, serü üretim sistemini kurmanın yanı sıra çeşitli düzenek ve mekanizmalar kurarak serü üretim sisteminin sorunlarına çözümler geliştirilmelidir.

Diğer taraftan, serü üretim insan merkezli bir üretim sistemi olduğundan ve bir ürünün tüm montaj işlemleri tek bir çalışan tarafından yapıldığından, ürün ve montaj işlemlerinde hatalar olabilmektedir. Nihai ürünlerdeki kalite kusurları yalnızca hatalı/kusurlu montaj ürünü bileşenlerinden kaynaklanmaz. Çalışanların montaj işlemlerini manuel olarak gerçekleştirdiği sistemlerdeki en yaygın ürün hatası kaynakları; yanlış ürün bileşenlerinin veya montaj araçlarının alınması, yanlış ürün bileşeninin monte edilmesi, montaj işlemlerinin yanlış bir şekilde gerçekleştirilmesi, montaj işlemlerinin yanlış bir sırada gerçekleştirilmesi, herhangi bir ürün bileşeninin montajının unutulması, herhangi bir montaj işleminin eksik yapılmasıdır. Bu hataların oluşumunda etkili olan, üretim verimliliğini azaltan, hurda ve yeniden işleme işlemlerine neden olan faktörler şu şekildedir (Bay ve Çiçek, 2007; Estrada ve ark, 2007; Siegel 2019);

- Çalışanların eğitim seviyesi, tecrübesi ve uzmanlığı,
- Çalışanların yorgunluk, dikkatsizlik ve sağlık gibi fiziksel ve zihinsel durumları,
- Çalışanların yetenekleri ve fiziksel özellikleri (bazı ürünlerde hassas montaj işlemleri için uygun olmayabilir),
- Fiziksel çalışma ortamı faktörleri ve duruş gibi ergonomik işyeri koşulları,
- Ürün bileşenlerinin ve montaj araçlarının yanlış konumlandırılması,

Manuel montaj sistemlerindeki bu hata kaynakları serü üretim sistemi için de geçerlidir. İlave olarak serü üretim sistemi için aşağıdaki faktörler de hata oluşumunda etkili olmaktadır:

- Yatailerde montaj işlemleri için gerekli tüm ürün bileşenlerinin ve montaj araçlarının bulunmaması ya da hatalı ürün bileşeni veya montaj araçlarının bulunması,
- Tüketilen ürün bileşenlerinin yataiye doğru zamanda tedarik edilmemesi veya yatailerde istifleme alanlarında biriken nihai ürünlerin zamanında alınmaması.

Bu kapsamda, serü üretim sistemindeki hataların gerçek zamanlı tespiti ve önlenmesi için yukarıda sözü edilen tüm faktörleri göz önünde bulunduran gerçek zamanlı bir kontrol sistemi gereklidir. Giuliano ve Taurino (2014), operatörün herhangi bir karmaşık operasyonda kendisine yardımcı olmak için artırılmış gerçeklik araçlarıyla desteklenebilmesi durumunda Serü tipi bir üretim hücresinin gerçekten karlı olabileceğini göstermeyi amaçlamışlardır. Yazarlar, yalın düşüncenin üretim hattının her aşamasında hata tespitinin yapılmasını, üretim sırasında sorun oluştuğunda üretimi durdurmayı ve bir sonraki sürece geçmeden önce hatayı düzeltmeyi gerektirdiğini belirtmişlerdir. Diğer taraftan, Yu ve ark. (2013a) ve Yu ve ark. (2014) gelecek çalışmalarda serü üretim sisteminde insan ve psikolojik faktörlerin ve farklı çevresel faktörlerin analiz edilmesinin de faydalı olacağını belirtmişlerdir. Zhang ve ark. (2017) hata önleme anlamına gelen poka-yoke ve dağıtım sistemi optimizasyonu gibi temel yardımcı teknolojilerin sürdürülebilir performans üzerinde çeşitli etkilere sahip olduğunu öne sürmüşlerdir. Bu tez çalışmasında geliştirilecek olan gerçek zamanlı serü üretim kontrol sisteminin literatürde bahsedilen birçok faktörü göz önünde bulundurması sayesinde literatürdeki bu boşluğu dolduracak ilk çalışmalardan birisi olacağı öngörülmektedir. Diğer taraftan, Yin ve ark. (2018a)'nın serü üretim sistemi de dahil olmak üzere geleceğin akıllı üretim sistemlerinin Endüstri 4.0'ın müşteri talep boyutlarına göre düzenlenmesi gerektiğini vurgulayan çalışmasında yazarlar, aşağıdaki üç araştırma yönünün gelecekte faydalı olabileceğini savunmaktadırlar. İlk olarak, büyük veri toplama ve değerlendirme konusu, IoT ile kolaylaştırılmalı ve gelişmiş optimizasyon, yapay zeka veya derin öğrenmeye dayalı verimli yaklaşımlar geliştirilmelidir. İkinci olarak, bir üretim sisteminin yeni teknolojiler ve müşteri talep boyutları ile bir ortama nasıl uyum sağladığı araştırılmalıdır. Üçüncüsü, Endüstri 4.0 kapsamında üretim sistemlerinin nasıl inşa edileceğini, yönetileceğini, işletileceğini ve bakımının nasıl yapılacağını açıklamak için titiz, derin ve ayrıntılı vaka çalışmaları önerilmektedir.

Yukarıdaki literatürde önerilen serü üretim sisteminin zeki üretim sistemlerine dönüştürülmesi ile ilgili bu tez çalışması kapsamında, Endüstri 3.0'da ortaya çıkan serü üretim sistemine ilave olarak sözü edilen Endüstri 4.0 teknolojileri eklenerek zeki serü üretim sistemi kavramsal modeli önerilmektedir. Önerilen zeki serü üretim sistemi kavramsal modeli altı bileşenden oluşmaktadır. Modelde bulunan dört bileşen montaj eylemlerinin tanınması modelini içermektedir. Bu nedenle bir sonraki bölümde montaj eylemlerinin tanınması çalışmalarının önemine ve literatürde montaj eylemlerinin tanınması ile ilgili yapılan çalışmalara yer verilmektedir.

2.2. Montaj Eylemlerinin Tanınması

Bir ürün üretmek için birden fazla iş parçasını bir araya getirme işlemi olan montaj faaliyetleri (Al-Amin ve ark, 2023), üretim sürecindeki önemli adımlardan birisi olmakla beraber (Wang ve ark, 2022b), toplam üretim maliyetinin %20'sini, toplam üretim süresinin ise %50'sini oluşturmaktadır (Fan ve Dong, 2003). Karmaşık makineler ve elektronik ürünler başta olmak üzere, bazı ürünlerin montajında manuel kullanımın hala vazgeçilmez olduğu bilinen bir gerçektir (Wu ve ark, 2020; Yin ve ark, 2018b). Bu nedenle, montaj süreçlerinin iyileştirilmesi verimliliğin artırılması için en önemli görevlerden birisi olarak görülmektedir (Maekawa ve ark, 2016). Montaj süreçlerinde bir montaj adımının atlanması veya bir operatörün düzensiz çalışması gibi faktörlerin ürün kalitesi üzerinde olumsuz etkileri bulunmaktadır (Chen ve ark, 2020a). Özellikle çok çeşitlilikte ve kişiselleştirilmiş ürünlerin montajında uygulanan serü üretim sisteminin türlerinden yatai ve dönel serüda bir ürünün tüm montaj işlemleri tek bir çalışan tarafından gerçekleştirilmekte, bu da hatalara dolayısıyla zaman ve para kaybına neden olabilmektedir. Montaj eylemlerinin gerçek zamanlı tanınması ile insan hatalarına gereken zamanda müdahale edilebilmesi sağlanabilir (Al-Amin ve ark, 2023). Montaj eylemlerinin tanınması süreci, insan aktivite tanıma araştırma alanına girmektedir (Chen ve ark, 2020b). İnsan aktivite tanımanın amacı, bir dizi gözlem ve çevre koşullarını kullanarak bireylerin eylemlerini tanımadır (Pushpalatha ve Math, 2022). Güçlü performans gösteren bir montaj eylemi tanıma modeli, çalışan hatalarının belirlenmesi, düzeltilmesi ve önlenmesi ile nihai ürünlerdeki hata oranının azaltılmasını sağlar (Sopidis ve ark, 2022). Bunun yanı sıra, montaj eylemi tanıma modeli ile montaj süreçlerine şu yetenekler kazandırabilir:

- Gerek yeni bir çalışanın proaktif bir çalışan rehberlik sistemi ile eğitilmesinde, gerekse herhangi bir çalışanın montaj sırasında desteklenmesinde, çalışanın şu anda hangi iş aşamasını yaptığına ve ne zaman bittiğine karar vermek ve gerçekleştirilen görevlere göre bir sonraki görev için otomatik olarak değişen talimatları vermek amacıyla montaj eylemi tanıma modeli kullanılabilir (Huikari ve ark, 2010; Koskimaki ve ark, 2009).
- Yukarıda bahsedilen montaj eylemlerinin tanınması modeli ile sağlanan eğitim ve yerinde yardım sayesinde, çalışanların gerekli becerilerde ustalaşması, performanslarının geliştirilmesi, çalışan üretkenliğinin artırılması ve ürün kalitesinin garanti edilmesi önemli ölçüde sağlanabilir (Tao ve ark, 2019).
- Destek faaliyetleri gerektiren değişen çalışma durumları belirlenebilir (Aehnelt ve ark, 2014).
- Çalışan performansının gerçek zamanlı ölçülmesinde ve değerlendirilmesinde yardımcı olabilir (Tao ve ark, 2018).
- Yönetici, çalışan işlem sürelerinin geçişlerinden, çalışanın yorgunluk derecesini ve işe ne ölçüde alıştığını tahmin edebilir (Maekawa ve ark, 2016).
- Montaj süre bilgilerinin ve hata sıklığının elde edilmesi ile, uygunluk kontrolü gibi yöntemler aracılığıyla montaj iş akışlarının optimizasyonu desteklenebilir (Knoch ve ark, 2020).
- Manuel montaj sistemlerinden gerçekleştirilen hareketlerin türleri, süreleri ve sıraları gibi gerçek zamanlı verilere erişim sağlanması, üretim planlama ve yeterlilik değerlendirmelerine katkıda bulunmanın yanı sıra kalite kontrol, lojistik planlama ve yönetim kararları için yararlı içgörüler sağlar (Liu ve ark, 2018a; Riedel ve ark, 2022).

Seru üretim sistemi ile ilgili literatür incelendiğinde, montaj eylemlerinin tanınması ile ilgili bir çalışmaya rastlanmamıştır. Montaj hattı ve montaj hücresi gibi diğer manuel montaj sistemlerinde ise montaj eylemlerinin tanınması ile ilgili sınırlı sayıda çalışma mevcuttur. Montaj eylemlerinin tanınması çalışmalarında insan aktivite tanıma çalışmalarında olduğu gibi verilerin toplanması yöntemleri açısından sensör tabanlı sistemler ve görüntü tabanlı sistemler olmak üzere iki ana yöntem bulunmaktadır. Montaj eylemlerinin tanınması uygulamalarında sensör tabanlı sistemlerde verilerin toplanması aşamasında ivmeölçer, jiroskop, elektromiyografi (sEMG) ve atalet ölçüm sistemi (IMU) gibi giyilebilir sensörler ve cihazlar yaygın bir şekilde kullanılmıştır

(Al-Amin ve ark, 2022; Azadi ve ark, 2019; Doppler ve ark, 2021; Günther ve ark, 2019; Huikari ve ark, 2010; Koskimaki ve ark, 2009; Maekawa ve ark, 2016; Soppidis ve ark, 2022; Tao ve ark, 2018; Ward ve ark, 2006). Ancak birden fazla sensörün kişinin vücuduna uzun süre takılı kalması, özellikle çok sayıda kablo bağlantısı nedeniyle çalışanlara rahatsızlık vermekte ve çalışanların rahat hareket etmesini engellemektedir. Aynı zamanda baskı oluşturarak üretkenliği etkilemekte ve uygulamada zorluklar oluşturmaktadır (Chen ve ark, 2020a; Khan ve ark, 2022; Tan ve ark, 2022). Yalnızca kontrollü laboratuvar ortamında başarılı olduğu kanıtlanan ve endüstriyel işyerlerinin karmaşıklıklarının üstesinden gelmek için uygun olmayan bu tür cihazların kullanımı, uygulama maliyetlerinin yüksek olmasına ve gürültülü ölçümlere yol açabilmektedir (Hernandez ve ark, 2021). Bu nedenle görüntü tabanlı yaklaşımlar araştırmacılar için oldukça ilgi çekici bir çalışma alanı haline gelmiştir. Bazı montaj eylemlerinin tanınması çalışmalarında giyilebilir sensörler ile birlikte kameralar kullanılarak çok modlu veri toplama araçlarından yararlanıldığı görülmüştür (Al-Amin ve ark, 2019; Al-Amin, 2021; Gu ve ark, 2021; Male ve Martinez-Hernandez, 2021; Tao ve ark, 2019; Tao ve ark, 2020a). Fakat sensör kullanımının bahsedilen zorluklarından dolayı bu tez çalışmasında veri toplama aracı olarak sadece kamera kullanılmıştır.

Görüntü tabanlı yaklaşımlarda veri toplama aracı olarak çeşitli RGB kameralar veya Kinect gibi derinlik kameraları kullanılmaktadır. Montaj eylemlerinin tanınması çalışmalarından bazıları RGB kameralar ile toplanan görüntüler üzerinde nesne tespiti yöntemlerinin uygulanması yaklaşımını benimsemişlerdir. Andrianakos ve ark. (2019) tarafından gerçekleştirilen çalışmada, manuel montaj işlemlerini otomatik olarak izlemek için tek bir webcam ile elde edilen görüntüler üzerinde farklı iş parçalarının ve çalışanın ellerinin tespit edilmesini birleştiren bir yaklaşım sunulmuştur. Önerilen yaklaşımda, bir nesnenin ve bir elin sınırlayıcı kutusu belirli bir oranda kesiştiğinde, nesnenin yakalanmış olduğu kabul edilir. Çalışmada, parça tespiti ve el tespiti için SSD (Single Shot Detector) yöntemi kullanılmıştır. Yaklaşım su pompası montajına ait 'taşıyıcı', 'kasnak' ve 'pompa' olmak üzere üç montaj bileşeninin montajı için test edilmiş ve etkinliği ispatlanmıştır. Yazarlara göre, çok küçük parçaların montajını gerektiren bir süreçte bu parçalar kolaylıkla tespit edilemeyeceğinden, montaj süreci takibinin yapılması çok daha zor olacaktır. Pimminger ve ark. (2019) çalışmalarında, montaj görevlerinin izlenmesi amacıyla, montaj parçalarının görsel olarak tanınması

için Halcon makine görmesi sistemi, montaj parçalarının ve araçlarının görsel olarak tanınması için Tensorflow Nesne Tespiti Uygulaması ve bir kutudan montaj parçalarının alınmasının ultrason tabanlı takibi için Marvelmind sistemi olmak üzere üç prototipin yardımıyla üç yaklaşımı karşılaştırmaktadır. Sonuç olarak, aydınlatma gibi sabit bir ortamın garanti edilebildiği ve her nesne için bir şablonun bulunduğu montaj parçaları kullanıldığında Halcon sisteminin, nesne perspektifi ve ışık durumu açısından esnekliğe ihtiyaç duyulduğunda ise TensorFlow'un tercih edilebileceği bildirilmiştir. Fakat TensorFlow uygulamasında etiketleme ve eğitim zaman alıcı bir süreçtir. Diğer taraftan karşılaştırılan bu sistemlerde cıvata gibi küçük boyutlu parçaların kameraların çözünürlüğü yeterince iyi olmadığı için tanınmadığını belirtmişlerdir. Bu da, bazı montaj adımları için önemli bir dezavantaj sağlamaktadır. Chen ve ark. (2020a)'nın yapmış oldukları çalışmada, çalışanların montaj sürecinin izlenmesiyle kilit operasyonel eksikliklerin ve çalışanların düzensiz çalışmalarından kaynaklanan montaj kalite sorunlarının önlenmesi amaçlanmıştır. Bu kapsamda tekrarlı ve montaj aracı bağımlılığı özelliğine sahip montaj eylemlerinin tanınması ve çalışma sürelerinin tahmin edilmesi için nesne tespiti ve poz tahmini teknolojileri kullanılmıştır. Montaj eylemlerinin tanınması deneylerinin gerçekleştirilmesi için 'törpüleme', 'çekiçleme' ve 'somun vidalama' olmak üzere üç çeşit montaj eylemi ele alınmıştır. Nesne tespiti olarak YOLOv3 algoritması uygulanarak montaj araçları tespit edilmiş ve elde edilen montaj araçları bilgisi montaj eylemlerinin tanınması için kullanılmıştır. %92,8 eylem tanıma doğruluğu oranına ulaşılmıştır. Montaj eylemlerinin sürelerinin tahmin edilmesi amacıyla insan eklemlerinin bilgilerinin çıkarılması için derin öğrenmeye dayalı OpenPose altyapısı kullanılmıştır. Tekrarlayan montaj işlemleri için çalışma sürelerini değerlendirmenin doğruluk oranı %82,1 olarak bildirilmiştir. Lou ve ark. (2022) tarafından gerçekleştirilen çalışmada gerçek zamanlı manuel işlemlerin tanınması ve tekrarlanan eylemlerin sayılması amacıyla iki aşamalı bir yaklaşım sunulmaktadır. Bu yaklaşımın ilk aşamasında, video görüntülerinden manuel işlemleri tanımak ve işlemlerin alt işlemlerini sınıflandırmak için YOLOv4-tiny nesne tespiti yöntemi, ikinci aşamasında ise, alt operasyonların farklı kategorilerinin uygun sınır noktalarını bulmak amacıyla Kayan Pencere Sayıcı algoritması kullanılmıştır. Geliştirilen yaklaşım bir hazır giyim fabrikasındaki 'kumaş yayma', 'işaretleme', 'kesme', 'dikme', 'düzeltme', 'kontrol etme', 'bitirme', 'presleme' ve 'paketleme' işlemlerini içeren 15 üretim hattı eylemi için ve 8 montaj hattı eylemi için toplanan iki video veri seti üzerinde uygulanmıştır. Özellikle çok

küçük boyutta montaj bileşenlerinin montajının gerçekleştirildiği elektronik endüstrisinde, operatör montaj işlemini gerçekleştirirken sınırlı görüşe sahip bileşenlerin tanınması ve doğru konumlarının belirlenmesi zor olmaktadır (Marin ve ark, 2022). Diğer taraftan, bir montaj aracı birden fazla montaj eyleminde kullanılabilirdiği ve bazı montaj işlemleri herhangi bir montaj aracı kullanımı gerektirmediğinden, montaj sürecinde kullanılan montaj araçlarının tespiti ile montaj eylemlerinin tanınması yaklaşımı ise yeterli ve verimli olmamaktadır. Bunlarla birlikte serü üretim sistemi herhangi bir montaj bileşeni ve montaj aracının kullanılmadığı test ve paketlenme gibi işlemleri de içermektedir. Bu nedenlerden dolayı, montaj eylemlerinde nesne tespitine dayalı eylem tanıma yaklaşımlarının kullanılması serü üretim sistemine tam olarak uygun olmamaktadır.

RGB kameralar ile elde edilen görüntüler üzerinde montaj eylemlerinin tanınması uygulamasını gerçekleştiren diğer bazı çalışmalar çalışan eylemlerini içeren video kliplerini çeşitli görüntü özelliklerini kullanarak sınıflandırmışlardır. Jiang ve ark. (2016) çalışmasında mekanik montaj işlemlerinin makine görüşüne dayalı segmentlere ayrılması yoluyla tanınması için bir yöntem önerilmektedir. İçerik tabanlı dinamik anahtar çerçeve çıkarma teknolojisi kullanılarak ilk önce video akışından anahtar çerçeveler çıkartılmıştır. Daha sonra, örnek görüntülerin ilgi bölgeleri elde edilerek bu ilgi bölgelerin Ölçek Değişmez Unsur Dönüşümü (Scale Invariant Feature Transform - SIFT) algoritması ile özellik noktaları çıkartılmıştır. Elde edilen özellik vektörlerinden montaj işlemlerinin sınıflandırılması için Destek Vektör Makineleri sınıflandırma algoritması kullanılmıştır. Önerilen yaklaşımın montaj hattından çekilen ve 4 tip therblig hareketini ('uzanma', 'kavrama', 'taşımaya' ve 'birleştirme') içeren örnek videoyu %96 oranında tanıma doğruluğunda olduğu belirtilmiştir. Rückert ve ark. (2021), manuel montaj işlemlerinin görsel sensör verilerinden sınıflandırılabilmesi için evrimsel LSTM katmanına sahip çok katmanlı bir sinir ağı modeli geliştirmişlerdir. 'Uzanma', 'kavrama', 'taşımaya', 'serbest bırakma', olmak üzere 4 temel Metot-Zaman Ölçümü (MZÖ) manuel montaj hareketini içeren görüntü veri seti oluşturmuşlardır. 'Uzanma' eylemi için %54, 'kavrama' eylemi için %39, 'taşımaya' eylemi için %70, 'serbest bırakma' eylemi için %55 doğruluk oranı elde etmişlerdir. Eğitim veri setinin boyutunu artırarak daha doğru bir sınıflandırma elde edilebileceğini vurgulamışlardır. Chen ve ark. (2020b)'nin yapmış oldukları çalışmada, montaj eylemlerinin tanınması için yığın normalizasyon katmanına sahip

üç boyutlu bir evrişimsel sinir ağı (3D CNN) modeli önermişlerdir. Modelin değerlendirilebilmesi için Kinect derinlik kamerası aracılığı ile ‘vida bükme’, ‘somun bükme’, ‘çekiçleme’, ‘bant sarma’, ‘sprey boyama’, ‘firçalama’, ‘kenetleme’, ‘testere’ ve ‘törpüleme’ olmak üzere 9 montaj eylemini içeren RGB video ve derinlik video formatında montaj eylemleri veri seti elde etmişlerdir. RGB görüntünün, ikili görüntünün, gri görüntünün ve derinlik görüntüsünün eğitim hızı ve doğruluğu üzerindeki etkilerini de araştırmışlardır. Yığın normalizasyonun eğitim parametrelerinin sayısını etkili bir şekilde azaltabileceği ve yakınsama hızını arttırabileceği sonucuna varmışlardır. RGB görüntüleri üzerinde yığın normalizasyona sahip model sayesinde %83,70 değeri ile en yüksek doğruluğa ulaşmışlardır. En düşük eğitim süresi ise gri görüntü veri setinde gerçekleşmiştir. Tao ve ark. (2020b), iki kamera ile farklı açılardan çekilerek elde edilen görüntü çerçevelerini montaj işlemi tanıma gerçekleştirmeyi amaçlamışlardır. Bu doğrultuda gerçek zamanlı tanıma için transfer öğrenme yaklaşımı yoluyla bir derin öğrenme modeli eğitilmiştir. Önerilen yaklaşımın doğruluğunu test etmek için masaüstü CNC makinesinin kurulmasına yönelik bir montaj görevinde 10 ardışık işlemi içeren bir çalışan montaj işlemi veri seti oluşturularak kullanılmıştır. Sonuç olarak yaklaşımın %95 tanıma doğruluğuna ulaştığı belirtilmektedir. Chen ve ark. (2022), montaj eylemlerinin tanınması için dikkat mekanizmasına ve çok ölçekli özellik füzyonuna bir grafik evrişimsel ağ modeli önermişlerdir. Geliştirilen modeli hazırlık davranışları, üretim ve montaj davranışları, düzensiz davranışlar ve dinlenme davranışları olmak üzere dört kategoriye ayırdıkları 15 işlemi içeren montaj davranışı veri seti üzerinde test etmişlerdir. Model sayesinde %93,1 oranında bir doğruluk elde etmişlerdir.

Bahsedilen çalışmalardan birçoğunun yüksek tanıma doğruluğu olmasına rağmen, montaj eylemlerinin tanınmasının karmaşıklığı oldukça yüksektir. Görüntüler üzerinden özniteliklerin çıkarılmasında kullanılan yaklaşımlardan birisi de insan iskeleti bilgilerini kullanmaktır (Kobayashi ve ark, 2019). İskelet tabanlı temsiller RGB tabanlı temsillere kıyasla verilerin daha düşük boyutlu olmasını sağlamaktadır (Silva ve ark, 2021). Bu nedenle, iskelet verileri, hareket tanımayı daha hızlı, hesaplama açısından verimli ve gerçek zamanlı çıkarımı sağlamada daha iyi hale getirir (Al-Amin ve ark, 2023). Bu nedenlerden dolayı, montaj eylemlerinin tanınması çalışmalarında bazı iskelet tabanlı eylem tanıma yöntemleri önerilmiştir. Eylem tanımda kullanılmak üzere iskelet verileri iki temel yaklaşım ile elde

edilebilmektedir: Kinect tabanlı yaklaşımlar ve bilgisayarlı görü tabanlı yaklaşımlar. Wang ve ark. (2019b) çalışma kalite kusurlarının maliyetini azaltmak ve iş gücü verimliliğini artırmak için operatörlere eylemlerini düzeltmeleri konusunda rehberlik etmeyi amaçlamaktadır. Bu amaçla montaj hattında operatörlerin montaj eylemlerinin gerçek zamanlı tanınması için hiyerarşik kümeleme tabanlı bir CNN modeli geliştirmişlerdir. Çalışan eklem noktalarının 3 boyutlu (3B) koordinatlarını elde etmek için Microsoft Kinect görsel sensörü kullanmışlardır. Geliştirilen sınıflandırma modeli Kinect tarafından sağlanan 3B koordinatlar yardımıyla hesaplanan uzaklık ve açı özelliklerini girdi verisi olarak kullanmaktadır. Geliştirilen modelin etkinliğini değerlendirmek için 11 tip therblig hareketini içeren video veri seti oluşturmuşlardır. Gerçekleştirilen deneyler sonucu %56'lık bir doğruluk değeri elde etmişlerdir. Al-Amin ve ark. (2023) bireyselleştirilmiş bir evrişimsel sinir ağları (CNN) sistemi önerdikleri bu çalışmada, insan iskelet verilerini kullanarak eylem tanıma faaliyetini gerçekleştirmeyi amaçlamaktadır. Çalışmada 17 vücut eklemının iskelet verileri Kinect sensörü kullanılarak elde edilmiştir. Altı adet bir kanallı CNN sınıflandırıcısından oluşan sistemin her biri, zaman serisi iskelet verilerinden elde edilen duruşla ilgili benzersiz bir özellik vektörü ile oluşturulmuştur. Altı sınıflandırıcı, transfer öğrenimi ve yinelemeli güçlendirme yoluyla herhangi bir yeni çalışana uyarlanmıştır. Ayrıca daha iyi bir performans için bireyselleştirilmiş bir füzyon yöntemi de sisteme entegre edilmiştir. Önerilen sistemin değerlendirilmesi için Bukito 3B yazıcının bir laboratuvar ortamında montajında yedi ardışık eylem içeren "kolun takılması" adımı ele alınmıştır. Çalışmada test edilen yeni çalışanlar grubunda %94 doğruluğa ulaşıldığı belirtilmiştir. Ghazal ve ark. (2019)'nın belirttiği gibi, Kinect-tabanlı yaklaşımları uygulayan bu araştırmalar cihaza bağımlıdır ve standart kameralardan elde edilen videolar dışında kullanılamazlar. Ayrıca, bu cihazların üretim ortamında yoğun bir şekilde konuşlandırılması gerektiği durumlarda maliyeti oldukça yüksek olabilmektedir (Liu ve ark, 2018a).

Bilgisayarlı görü-tabanlı yaklaşımlar ise poz özelliklerini çıkarmak için vücuda herhangi bir cihaz takılmasını gerektirmeyen bilgisayarla görme tekniklerini kullanmaktadırlar (Wu ve ark, 2021b). Bu çalışmalarda özel poz tahmini yaklaşımlarının geliştirilmesinin yanı sıra OpenPose ve MediaPipe gibi çeşitli poz tahmini yaklaşımları da uygulanabilmektedir. Yonemoto ve ark, (2015) ben-merkezli (ego-centric) RGB-D video görüntülerinden eylem tanımadaki kullanılmak üzere el

tespiti, kamera pozu tahmini ve zaman serisi filtrelemeyi vücut şekli kısıtlamasıyla entegre eden ve üst vücut iskeleti pozunu tahmin eden yeni bir insan poz tahmini yöntemi önermişlerdir. Önerilen yöntemle tahmin edilen 3B iskelet verilerini kullanarak 5 montaj eylemi için Saklı Markov Modeline dayalı montaj eylem tanıma modeli geliştirmişlerdir. Kobayashi ve ark. (2019) yaptıkları çalışmada, montaj iş sahnelerindeki ayrıntılı hareketleri açıklamak için çalışanın ellerini ön plana çıkararak montaj eylem segmentasyonunu ele almışlardır. Çalışmada, özellik çıkarımı aşamasında her bir video karesi için görüntü özellikleri ve poz özellikleri elde edilerek birleştirilir. Poz özelliklerinin çıkarılmasında iki farklı yöntem karşılaştırılmıştır. Bu yöntemlerden biri olan OpenPose 2 boyutlu (2B) üst vücut eklemlerini çıkarmak için kullanılmıştır. Diğer yöntemde ise 2B el konumlarını algılamak için ResNet50 tabanlı bir regresyon modeli eğitmişlerdir. Görüntü özellikleri ise tanıma sürecinin dikkatinin odaklandığı ellerde kırılmış görüntülerden çıkarılır. Elde edilen özellikler, kodlayıcı-kod çözücü zamansal evrimsel ağlara (TCN) dayanan bir eylem sınıflandırıcı modele zamansal kalıplar olarak sunulur. Model 11 montaj eylemini içeren montaj iş veri kümesi oluşturularak test edilmiştir. Sonuç olarak yöntemin %86,2 doğrulukla etkili olduğu belirtilmiştir. Yang ve ark. (2020) montaj hattında manuel montaj eylemi tanıma için OpenPose ile elde edilen 2B poz verilerini girdi olarak alan bir Uzaysal-Zamansal Grafik Evrişim Ağı derin öğrenme yöntemine dayalı bir model geliştirmişlerdir. El hareketlerini beş tip therblig hareketleri olarak da adlandırılan 5 temel hareket ile tanımlamışlardır: ulaşma, yükü taşıma, montaj, tutma, basma. Deneysel çalışmalarda ortalama 72.8% doğruluk oranına ulaşmışlardır. Riedel ve ark. (2022) montaj hattında Zaman Etüdü çalışmalarında kullanılmak üzere, tek bir RGB kamera görüntülerinden ‘uzanma’, ‘kavrama’, ‘bırakma’, ‘yerleştirme’, ve ‘taşıma’ olmak üzere 5 temel MZÖ-1 manuel montaj hareketini tahmin etmek için derin öğrenmeye dayalı iki aşamalı bir yaklaşım önermişlerdir. Yaklaşımında öncelikle ellerin 3B eklem koordinatlarının çıkarılması için MediaPipe Hands modeli kullanılmıştır. Daha sonra elde edilen iskelet verileri ile Uzaysal-Zamansal Tekrarlayan Grafik Evrişim Ağı modeli geliştirilmiştir. Geliştirilen model ile %85,68 doğruluk oranı elde etmişlerdir.

Bunların yanında hem nesne tespiti hem de iskelet tabanlı metodoloji geliştirmiş çalışmalar da bulunmaktadır. Yamazaki ve ark. (2018) tarafından gerçekleştirilen çalışmada montaj işleminin tanınması için nesne ve el pozlarını içeren yöntem

önerilmiştir. Yöntemde ilk olarak çalışan 3B menzilli bir kamera önünde montaj eylemini gerçekleştirmektedir. Montaj eylemi 3B nesne pozları ve el hareketleri açısından tanınmaktadır. Poz tahmini LINEMOD şablon eşleştirme yöntemi ile insan el poz tahmini ise OpenPose ile gerçekleştirilmiştir. Elde edilen sonuçlar birleştirilerek olasılıksal yaklaşımla montaj hareket sınıfı elde edilmiştir. Fukuda ve ark. (2020) çalışmasında, ilk olarak montaj görevi sırasında insanın hareketine ilişkin bir zaman serisi verisi elde etmek amacıyla OpenPose altyapısı ile poz tahmini uygulanmıştır. Ardından YOLO nesne tespiti yöntemi ile kullanıcının kavradığı montaj parçaları ve araçlarının belirlenmesi hedeflenmiştir. Elde edilen bu bilgiler daha sonra montaj eylemlerinin sınıflandırılması için birleştirilmiş ve Saklı Markov Modeli eğitilmiştir. Önerilen yöntem ‘almak’, ‘tutmak’, ‘taşımak’, ‘eklemek’, ‘vidalamak’ ve ‘yerleştirmek’ olmak üzere altı montaj eylemine sahip bir oyuncak uçağın montaj süreçlerinde değerlendirilmiştir. Coronado ve ark, (2021) çoklu kamera sistemleri kullanarak nesne tespiti ve poz tahminini birleştiren ve montaj eylemlerinin analiz edilmesini sağlayan bir yazılım mimarisi çalışması gerçekleştirmişlerdir. Vücut ve el anahtar noktası tespiti için OpenPose ve MediaPipe tabanlı farklı yaklaşımları karşılaştırmışlardır. Montaj nesnelерinin tespiti için YOLO tabanlı derin öğrenme modelini kullanmışlardır. Elle manipüle edilen nesneyi tanımlanması için ve elde edilen özellikleri kullanarak montaj eylemlerinin tanınması için olmak üzere iki LSTM modülü geliştirmişlerdir. Sunulan çözümlerin performansını ve uygunluğunu değerlendirmek için oyuncak bir uçağın montaj görevinden elde edilen verileri kullanmışlardır. Eğitim verilerinin artırılması için Gauss gürültüsünü kullanarak iki veri seti eklemiştirler. Deneysel sonuçlar LSTM modeline dayalı yaklaşımın Saklı Markov Modellerine (HMM) göre daha iyi tanıma doğruluğu sağladığını göstermiştir. OpenPose tabanlı çözümler %63,04 ile daha iyi tanıma oranları sağlayabilmişken, MediaPipe tabanlı bir çözüm, gerçek zamanlı veri işleme için uygun olabilecek daha az hesaplama kaynağıyla %51,02 değeri ile kabul edilebilir doğruluk sunabilmiştir.

Bu tez çalışmasında, RGB kamera ile toplanan video görüntülerinden elde edilen insan iskelet verilerinden yararlanarak insan aktivitelerinin tanınması amaçlanmaktadır. Bu amaçla çalışmada, RGB video görüntülerinden insan iskelet eklemlerinin 3B konumlarını çıkarmak için Huang ve ark, (2022)’nin çalışmasında olduğu gibi, özellikle anahtar noktaların daha sonra işlenmesi gerektiği durumlarda diğer poz tahmini yaklaşımlarına göre daha hızlı bir poz kestirim algoritması sağladığı için

MediaPipe altyapısından yararlanılmıştır. Çalışmada sadece ellerdeki kilit noktaların poz verilerinden elde edilecek veri seti ve ellerdeki kilit noktalar ile vücuttaki kilit noktaların poz verilerinin birleştirilmesi ile elde edilecek veri seti kullanılarak geliştirilecek olan modeller karşılaştırılmaktadır.

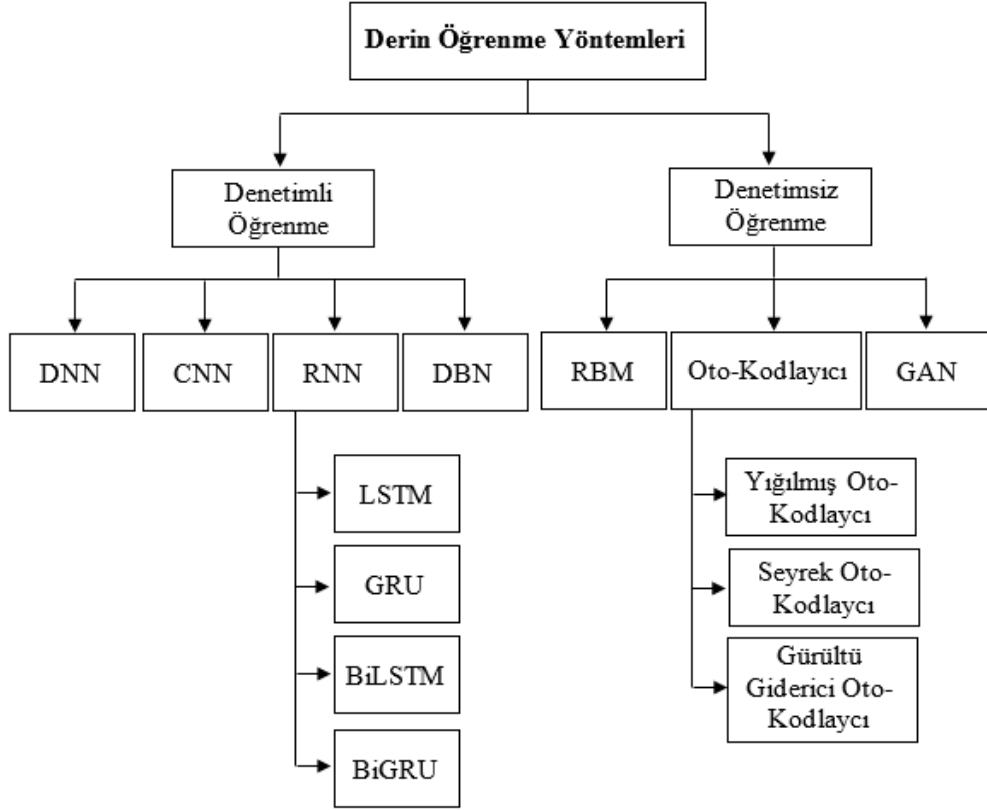
Montaj eylemlerinin tanınması alanındaki çalışmalar incelendiğinde, makine öğrenmesi (Koskimaki ve ark, 2009; Huikari ve ark, 2010; Fukuda ve ark, 2020; Gu ve ark, 2021) ve derin öğrenme (Kobayashi ve ark, 2019; Wang ve ark, 2019b; Rückert ve ark, 2021; Chen ve ark, 2022) tabanlı birçok model geliştirildiği görülmektedir. Bayes Ağları, Destek Vektör Makineleri ve Markov modelleri gibi bu çalışmalarda kullanılan geleneksel makine öğrenmesi algoritmaları genellikle insan alanı bilgisi ile sınırlı ve zaman alıcı olan el yapımı özellikler gerektirirler (Dang ve ark, 2020; Ma ve ark, 2019). Son zamanlarda, derin öğrenme tabanlı yöntemler insan aktivite tanıma ve dolayısıyla montaj eylemlerinin tanınması alanında oldukça fazla dikkat çekmektedir (Zhang ve ark, 2022c). Derin öğrenme, özellik çıkarma iş yükünü büyük ölçüde azaltabilir ve özellikleri düşük seviyeden yüksek seviyeye otomatik olarak çıkarabilir (Huan ve ark, 2021). Literatürde derin öğrenmeye dayalı geliştirilen eylem tanıma çalışmaları, esas olarak CNN ve RNN varyant mimarilerine odaklanmaktadır. CNN tabanlı mimariler uzamsal bilgi çıkarılmasını sağlarken, LSTM, GRU, BiLSTM ve BiGRU gibi RNN tabanlı mimariler zamansal özelliklerin çıkarılmasında önemli bir rol oynamaktadır. İnsan aktivite tanımada olduğu gibi montaj eylemlerinin tanınması verileri, uzamsal ve zamansal bilgileri içeren zaman serisi verileridir. Bu nedenle, bu çalışmalarda aynı anda her iki bilgiyi de çıkarma potansiyeline sahip sağlam bir model geliştirilmesi gerekmektedir (Khan ve ark, 2022). Bu tez çalışması kapsamında, CNN tabanlı mimariler, RNN tabanlı mimariler ve bu algoritmaların birlikte kullanımları ile hibrit mimariler geliştirilerek çeşitli derin öğrenmeye dayalı montaj eylemlerinin tanınması modelleri geliştirilmektedir.

Literatür incelendiğinde, montaj eylemlerinin tanınması sayesinde sadece hatalı montaj eylemlerinin belirlenmesi değil, aynı zamanda çalışan eğitimi, çalışan performansının değerlendirilmesi, çalışan beceri seviyelerinin tespit edilmesi ve çalışan yorgunluğunun belirlenmesi gibi birçok görevin gerçek zamanlı olarak gerçekleştirilebileceği sonucuna varılmaktadır. Çalışmalar, montaj görevlerini gerçekleştiren çalışanlara rahatsızlık verebilen giyilebilir sensörlerin kullanımından ziyade, görüntü tabanlı yaklaşımların montaj eylemlerinin tanınması amacıyla

kullanımının daha uygun olduğunu bildirmişlerdir. Özellikle gerçek zamanlı veri işleme yeteneğine sahip MediaPipe kütüphanesi ile poz tahmini sayesinde insan hareketleri hakkında yararlı olabilecek detaylı insan iskelet verileri elde edilebilmektedir. Bu nedenle bu çalışmada, montaj eylemlerinin tanınması amacıyla kamera ile toplanan video görüntülerinden MediaPipe altyapısından yararlanarak elde edilen insan iskelet verilerinden faydalanılması planlanmıştır. Literatür analiz edildiğinde, derin öğrenmenin insan aktivite tanıma alanında göstermiş olduğu yüksek sınıflandırma yeteneği sayesinde, montaj eylemlerinin tanınması alanında da kullanıldığı anlaşılmaktadır. Karmaşık problemlerde özellik çıkarımındaki başarısı, çeşitli alanlarda geleneksel makine öğrenmesi yöntemlerine olan üstünlüğü, tepki sürelerinin hızındaki yüksek performansı nedenlerinden dolayı bu çalışmada önerilen ve montaj eylemlerinin tanınması modelini de içeren altı bileşenli kavramsal model derin öğrenme yöntemlerine dayalı olarak geliştirilmiştir. Bir sonraki bölümde derin öğrenmenin tanımı, derin öğrenme yöntemleri, bu yöntemlerin kullanım alanları, avantajları ve dezavantajlarına yer verilmektedir.

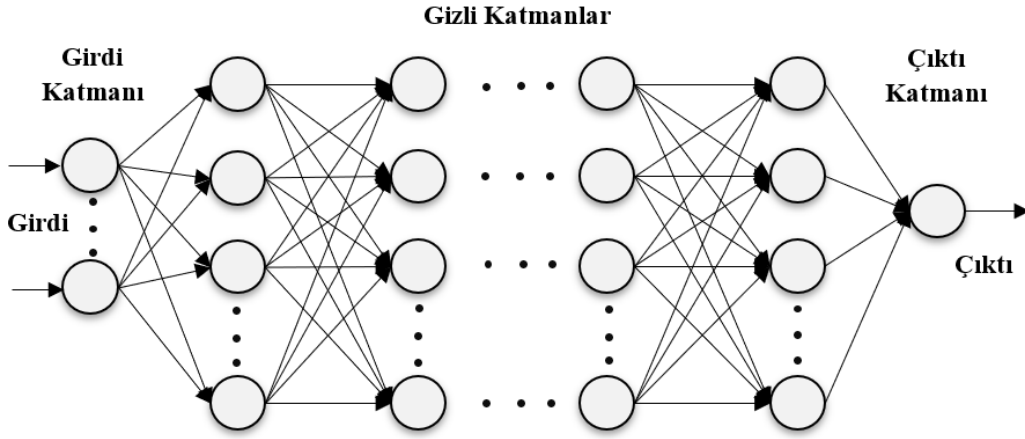
2.3. Derin Öğrenme

Makine öğrenmesinin bir alt alanı olan derin öğrenme, yapay sinir ağlarına dayanmaktadır. Oishi ve Yagawa (2017), derin öğrenmenin tanımının LeCun ve ark. (2015) tarafından üçten fazla gizli katmanı olan sinir ağlarını geliştirmek olarak yapıldığını belirtmişlerdir. Derin öğrenme, ağ katmanları artırıldığında genellikle yerel optimumlara düşme ihtimaline sahip yapay sinir ağını iyileştirme çabalarıyla başlamıştır (Leng ve ark, 2018). Derin öğrenme yapısında, daha karmaşık ve doğrusal olmayan ilişkileri modellemek amacıyla geleneksel sinir ağı (Neural Network - NN) mimarisine daha fazla gizli katman eklenir (Martín ve ark, 2018; Mohsen ve ark, 2018). Yaygın olarak kullanılan derin öğrenme yöntemlerinin öğrenme türlerine (denetimli öğrenme ve denetimsiz öğrenme) göre sınıflandırılması Şekil 2.3'te verilmektedir.



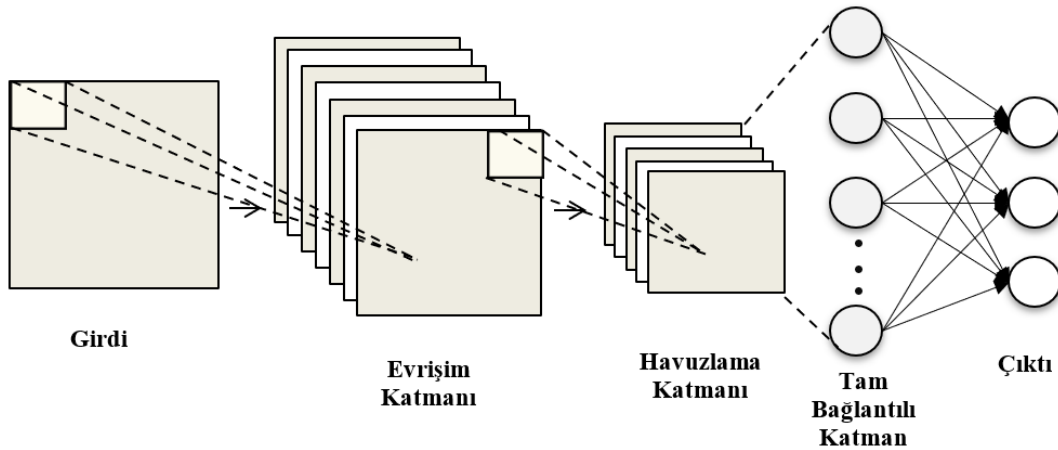
Şekil 2.3. Derin öğrenme yöntemlerinin sınıflandırılması, Liu ve Lang (2019)'dan uyarlanmıştır.

Derin öğrenme yöntemlerinden denetimli öğrenme kategorisinde bulunan derin sinir ağı (Deep Neural Network - DNN), standart bir sinir ağına benzer. DNN tarafından amaç fonksiyonuna yaklaşmak için bir dizi özellik öğrenilebilir (Martín ve ark, 2018). DNN, başarılı regresyon veya sınıflandırma uygulamaları için en yaygın olarak kullanılan derin öğrenme mimarisidir (Mohsen ve ark, 2018). Şekil 2.4'te gösterildiği gibi, DNN'ler normal yapay sinir ağlarından daha derindir, yani ağ yapısına daha fazla katman eklenir, bir nöron katmanından elde edilen çıktı, bir sonraki katman için girdi görevi görür (Dong, 2018; Hegelich, 2017). DNN genellikle diğer derin öğrenme modelleri için yoğun katman veya tam bağlantılı katman (dense layer) görevi görür. Örneğin, evrişim katmanlarından sonra, bir CNN'e birkaç yoğun katman eklenir (Wang ve ark, 2019c).



Şekil 2.4. İleri beslemeli sinir ağının temel yapısı.

Bir CNN, genellikle her katmanda birden çok nöron bulunan birden çok farklı sinir ağı katmanından oluşan derin bir ileri beslemeli yapay sinir ağıdır (Wan ve ark, 2020). Yüksek hacimli girdi verilerinden özellikler elde etmek için evrişim işlemleri gerçekleştiren bir CNN Şekil 2.5’te gösterildiği gibi genel olarak tek bir giriş, en az bir evrişim ve havuzlama katmanı ve en az bir tam bağlantılı katman içermektedir (Nafea ve ark, 2022). Bu yapıda evrişim katmanları özellikleri çıkarmak, havuzlama katmanları çıkarılan özelliklerin genelleştirilebilirliğini geliştirmek için kullanılırken (Liu ve Lang, 2019), tam bağlantılı katmanlar ise regresyon veya sınıflandırma görevini gerçekleştirmek için kullanılmaktadır. CNN, sinyallerden önemli ölçüde özellik çıkarma yeteneğine sahiptir ve görüntü sınıflandırma, metin analizi ve konuşma tanıma alanlarında başarısını kanıtlamıştır (Wang ve ark, 2019c).



Şekil 2.5. Evrişimsel sinir ağının temel yapısı.

En tipik derin öğrenme modelleri arasında en sık kullanılan diğer modeller yığılmış otomatik kodlayıcı (Stacked Autoencoder - SAE), derin inanç ağı (Deep Belief

Network - DBN) ve RNN'dir (Zhang ve ark, 2018a). SAE, birkaç otomatik kodlayıcı katmanından oluşan hiyerarşik bir ağıdır. SAE ağında eğitim için katmanların denetimsiz hırslı eğitilmesi (greedy layer-wise) algoritması kullanılır (Wei ve ark, 2018). Bu yöntem, düğümlerin birbirine çok fazla uyum sağlamasını önler ve sonuç olarak aşırı-eğitimden kaçınır. DBN'ler, yığılanmış Kısıtlı Boltzmann Makinelerine (Restricted Boltzmann Machine - RBM) dayalı olasılıksal üretken modellerdir. DBN'ler, gerçek zamanlı sınıflandırma, boyut azaltma, ses sınıflandırma ve yüz ifadesi tanıma dahil olmak üzere çeşitli zor öğrenme problemlerinde kullanılmıştır (Dairi ve ark, 2018).

Derin öğrenme yöntemlerinin popülerliğinin artmasıyla birlikte zaman serileri tahmini için yeni yaklaşımlar geliştirilmiştir (Kühnert ve ark, 2021). RNN ve LSTM ağları, çıktının bir girdiler dizisine bağlı olduğu sıralı bilgileri kullanmak için en sık kullanılan mimarilerdir (Lore ve ark, 2018). İleri beslemeli sinir ağlarının hafızaları bulunmadığından girdi verileri, veri girişi arasında bir durum kaydedilmeden bağımsız olarak işlenmektedir. Zaman serisi analizinde bu çeşit bir ağ kullanımı, ağın bir defada tüm zaman serileriyle beslenmesini gerektirir (Rocha ve Rodrigues, 2021). Bir RNN, sıralı verileri işlemek için tasarlanmış, gizli katmanın çıktısının ağa geri döndürüldüğü belirli bir sinir ağı mimarisini ifade eder (Jadidi ve ark, 2021; Shi ve ark, 2017). Geleneksel sinir ağlarından farklı olarak, çıktıyı tahmin etmek amacıyla girdi verilerinin zamansal davranışını tutmak için dahili belleğini kullanır (Prabhu ve ark, 2021) ve önceki adımın çıktılarını mevcut aşamaya besler (Elshaboury ve ark, 2021). RNN ağı ileri beslemeli bağlantıya ek olarak, giriş verilerinin dinamik değişikliklerini hızlı bir şekilde yansıtabilmesini sağlayan dahili geri bildirim bağlantılarına da sahiptir (Fu ve ark, 2016). RNN'lerin sonuçları, zaman serisi tahmin problemlerinde başarılı olmuştur (Shi ve ark, 2017).

RNN, zaman serisi problemleri için geliştirilmiş olsa da, uzun zaman serisi problemlerinde bilginin uzunluğunun değişmesi nedeniyle gradyanların kaybolmasına veya patlamasına neden olabilir (Zhu ve ark, 2018). LSTM modeli bu problemin çözülmesi için özel bir RNN yaklaşımı türü olarak geleneksel RNN'in iyileştirilmesiyle Hochreiter ve Schmidhuber (1997) tarafından geliştirilmiştir. İlgili giriş sinyalleri arasında çok uzun bağımlılıklar olan sıralı girişleri işleyebilmektedir (Kraus ve Feuerriegel, 2017). LSTM, durum bilgilerini saklamak için hücreleri ve hücrenin durumunu kontrol etmek için ise giriş kapılarını, unutma kapılarını ve çıkış

kapılarını içeren bir geçit yapısını kullanır (Li ve ark, 2021). Giriş kapısı bellek hücresine girdi akışını, çıkış kapısı çıkış akışını kontrol eder. Unutma kapısı, bellek hücresinin unutma sürecini kontrol eder (Kina ve ark, 2021). Unutma kapılarının kullanım amacı sayısal dengesizliklerin üstesinden gelmek amacıyla geri yayılım sürecinde gradyanların patlamasını önlemektir (Kraus ve Feuerriegel, 2017).

LSTM'nin doğruluğunun diğer algoritmalara göre daha yüksek olmasına rağmen, eğitim süresinin daha uzun olduğu bildirilmektedir (Wang ve ark, 2018a). Cho ve ark. (2014) tarafından tanıtılan ve daha az parametreye sahip olan GRU, LSTM'in bir varyasyonudur. Kapı mekanizması yoluyla RNN'lerin gradyan kaybolması sorununu büyük ölçüde azaltması özelliği açısından LSTM'nin etkisini korurken yapıyı daha basit hale getirmektedir (Shen ve ark, 2018). LSTM'ye benzer olmasına rağmen, LSTM'nin unutma ve giriş kapılarını tek bir güncelleme kapısında birleştirir (Dutta ve ark, 2020). Önceki anın durum bilgisinin mevcut duruma getirilme derecesini kontrol eden güncelleme kapısı ve önceki anın durum bilgisinin ihmal derecesini kontrol eden sıfırlama kapısı olmak üzere sadece iki kapısı bulunmaktadır (Cao ve ark, 2020).

LSTM ve GRU'ya ek olarak, verilen girdi verilerini eğitim için iki kez kullanan BiLSTM ve BiGRU algoritmaları geliştirilmiştir. BiLSTM ağ yapısı, LSTM ağ yapısından farklı olarak çift yönlüdür, yani zaman serisini işlerken hem ileri hem de geri çalışmak için iki gizli katman kullanır. Bu iki katman aynı çıktı katmanına bağlıdır. Bu sayede tahmin performansı LSTM'den daha iyidir (Yang ve Wang, 2022). GRU sadece bir önceki anın bilgisine dayanarak bir sonraki anın çıktısını tahmin edebildiği gibi BiGRU da bu anın bilgisini arkadan öne alarak bu anın içeriğini tahmin edebilir. Genel yapısı BiLSTM ile aynı olsa da hafıza yapıları farklıdır (Xu ve ark, 2022).

Günümüzde derin öğrenmenin yeniden canlanmasının altında yatan üç ana neden şu şekilde sıralanabilir: çip işleme yeteneklerindeki (örneğin GPU birimleri) çarpıcı artış, önemli ölçüde azaltılmış bilgi işlem donanımı maliyetleri ve makine öğrenmesi algoritmalarındaki önemli gelişmeler (Guo ve ark, 2016). Doğruluğu, verimliliği ve esneklik yeteneği sayesinde insan aktivite tanıma (Bianchi ve ark, 2019; Bilen ve ark, 2016; Ji ve ark, 2012; Ronao ve Cho, 2016; Sing ve Vishwakarma, 2018; Sing ve ark, 2019; Xu ve ark, 2019a), nesne tespiti/izleme (Huang ve ark, 2020; Karim ve ark, 2019; Ma ve ark, 2020; Mhallaa ve ark, 2019; Pérez-Hernández ve ark, 2020; Pi ve ark, 2020), zaman serileri tahmini (Chen ve ark, 2018; Moews ve ark, 2019; Rodrigues

ve ark, 2019; Xiao ve ark, 2019), duruş analizi (Abobakr ve ark, 2019; Zhang ve ark, 2018b), iç ortam kalite analizi (Ahn ve ark. 2017; Athira ve ark, 2018; Soh ve ark, 2018), tahmin/sınıflandırma (Akyol, 2020; Asghari ve ark, 2020), teslim süresi tahmini (Wang ve Jiang, 2019), çalışan performans değerlendirmesi uygulamalarında büyük başarı elde etmiştir. Derin öğrenme tekniği çok az manuel mühendislik gerektirir, bu nedenle mevcut hesaplama ve veri miktarındaki artışlardan kolayca yararlanabilir. Diğer geleneksel makine öğrenme teknikleri ve sığ sinir ağları ile karşılaştırıldığında, daha yüksek bir genelleme kabiliyetine sahiptir ve daha geniş bir girdi bilgisine dayanabilir (Leng ve ark, 2018).

Bahsedilen avantajlarından dolayı bu çalışmada önerilen zeki serü üretim sisteminin altı bileşeninin izlenmesi ve kontrol edilmesi için tasarlanmış olan sistem mimarisi derin öğrenme yöntemlerine dayalı olarak geliştirilmiştir. Her bir bileşende kendi görevlerini gerçekleştirecek olan modeller (insan aktivite tanıma, nesne tespiti / izleme, zaman serisi tahmini, duruş analizi, iç ortam kalite analizi, tahmin / sınıflandırma, teslim süresi tahmini, çalışan performans değerlendirmesi) bu sistem mimarisini temel alacak ve kendisine uygun derin öğrenme yöntemleri üzerine inşa edilecek şekilde yapılandırılacaktır. Bir sonraki bölümde tez çalışmasının literatürdeki diğer çalışmalardan farkı açıklanmakta, literatüre katkısı aktarılmaktadır.

2.4. Tezin Literatürdeki Çalışmalardan Farkı ve Literatüre Katkısı

Literatürde serü üretim sistemi ile ilgili çalışmalar incelendiğinde, Bölüm 2.1.3'te detayları verilen dezavantajlar olduğu görülmektedir. Bu dezavantajların giderilmesi için serü üretim sistemindeki hataların gerçek zamanlı tespiti ve önlenmesi konusunda gerçek zamanlı bir kontrol sistemi gereklidir. Bu sistemin daha önce ele alınmamış olan altı bileşen çerçevesinde tasarlanmış olması çalışmanın literatürdeki en önemli farkı ve katkısıdır. Diğer katkıları ise şu şekilde sıralanabilir:

- Geliştirilecek olan gerçek zamanlı serü üretim kontrol sistemi literatürde bahsedilen birçok faktörü (çalışanların eğitimi, çalışanlar üzerindeki baskı ve montaj süreçlerinde hatalara neden olabilecek etmenler gibi) göz önünde bulundurmaktadır.
- Daha önce Endüstri 3.0 kapsamında tasarlanmış olan serü üretim sistemine Endüstri 4.0 teknolojilerinin (nesnelerin interneti, akıllı cihazlar, ağ altyapısı, derin öğrenme ve makine öğrenmesi algoritmaları, bulut teknolojisi, artırılmış

gerçeklik, raporlama araçları) entegrasyonu çerçevesinde çeşitli yaklaşımlar önerilmiştir.

- Son zamanlarda farklı araştırma alanlarında sıklıkla kullanılan insan aktivite tanıma, nesne tespiti, poz tahmini ve tahmin /sınıflandırma gibi çeşitli derin öğrenmeye dayalı modellerin önerilen zeki serü üretim sisteminin altı bileşeninde uygulanmaları konusunda yol gösterilmiştir.
- Derin öğrenme kullanılarak serü sisteminin izlenmesi ve kontrol edilmesi için genel bir sistem mimarisi sunulmuştur.

Önerilen kavramsal modelin altı bileşeninden dördünün bünyesinde bulunan montaj eylemlerinin tanınması modeli için detaylı metodoloji geliştirilmiştir. Serü üretim sistemi ile ilgili literatür incelendiğinde, montaj işlemlerinin tanınması ile ilgili bir çalışmaya rastlanmamıştır. Serü üretim sistemi kontrolü için montaj eylemlerinin tanınması amacıyla, derin öğrenmeye dayalı poz tahmini modeli, veri artırma yaklaşımı ve derin öğrenme zaman serisi sınıflandırma algoritmalarının hibrit kullanımı ile gerçek zamanlı bir model geliştirilmiştir. Bu model bir ürünün montaj sürecinin baştan sona tamamlanması için gerçekleştirilmesi gereken tüm montaj eylemlerinin gerçek zamanlı tanınması yeteneğine sahiptir. Çalışmanın bu bölümünün temel katkıları şu şekildedir:

- Montaj eylemi tanıma modellerine video görüntülerinden girdi verileri elde edilmesi amacıyla poz tahmini modeli uygulanarak çalışan iskelet konumları verilerinin elde edilmesinde MediaPipe altyapısı kullanılmıştır. Literatürden farklı olarak sadece ellerdeki kilit noktaların poz verileri ile modellerin geliştirilmesinin yanı sıra ellerdeki kilit noktaların poz verilerine ek olarak vücuttaki kilit noktaların poz verilerinin de kullanılmasının montaj eylemi tanıma modellerindeki etkileri de detaylı olarak ele alınmıştır.
- Diğer montaj eylemlerinin tanınması çalışmalarından farklı olarak otomatik özellik çıkarma yeteneğine sahip derin öğrenmeye dayalı on farklı model geliştirilmiştir. Bu modeller uzamsal bağımlılıkları yakalayabilen CNN modeli, zamansal bağımlılıkları yakalayabilen Tekrarlayan Sinir Ağı (Recurrent Neural Network – RNN) tabanlı modeller ve bu modellerin birlikte kullanımları ile hibrit modelleri kapsamaktadır.

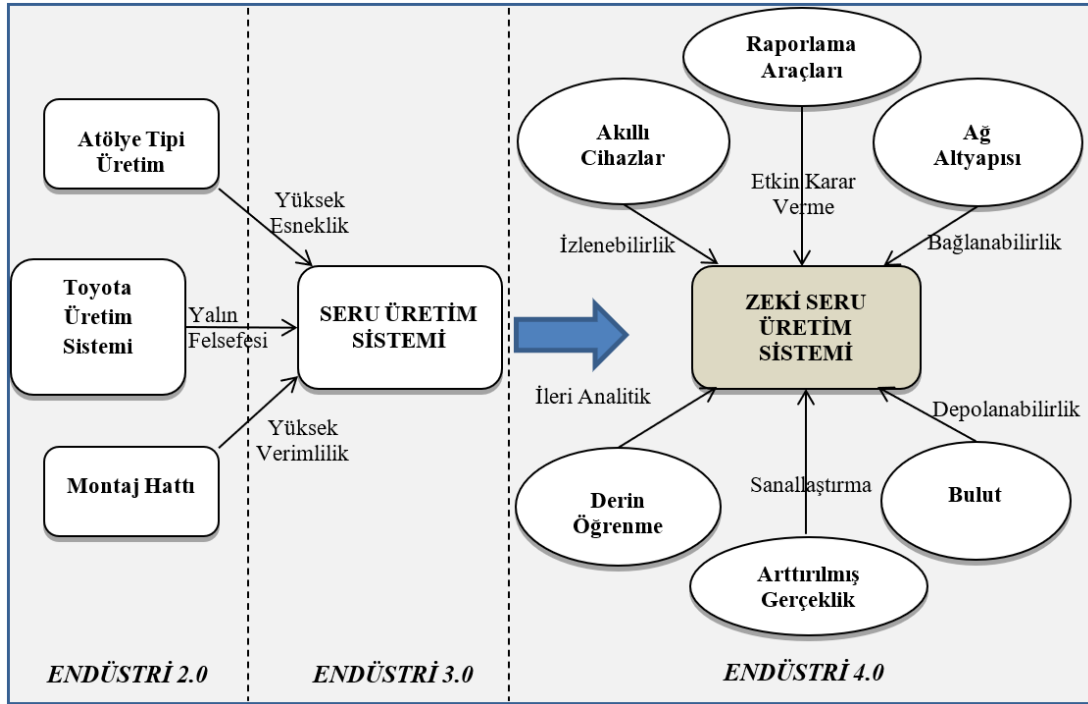
- Geliştirilen modellerden montaj eylemlerinin tanınması literatüründe rastlanmayan CNN-BiGRU-CNN modeli hem uzamsal hem de zamansal bağımlılıkları yakalama özelliğine sahip bir modeldir.
- Modellerin tanıma performansının geliştirilmesi için elde edilen poz verilerine uygulanmak üzere literatürde bulunan aşağı örnekleme ve ölçekleme yaklaşımları bütünleşik şekilde kullanılarak veri arttırma yaklaşımı geliştirilmiştir ve etkinliği test veri setleri üzerinde araştırılmıştır.
- Geliştirilen modellerin etkinliği hem montaj hattı hem de serü üretim sisteminden elde edilen veriler üzerinde test edilmiştir.

Bir sonraki bölümde tez çalışması kapsamında önerilen zeki serü üretim sistemi kavramsal modeli, sistemin ana bileşenleri ve bu ana bileşenler için tasarlanmış sistem mimarisi detayları anlatılmaktadır.

3. ZEKİ SERU ÜRETİM SİSTEMİ MODELİ ÖNERİSİ

Bu çalışmada, seru üretim sisteminin bahsedilen eksiklikleri nedeniyle altı bileşenli bir zeki seru üretim sistemi modeli önerilmiştir. Çalışan, müşteri, tedarikçi, yönetim, iş istasyonu ve depo gibi birçok sistem katılımcısından oluşan seru üretim sistemi montaj süreci gerçek zamanlı olarak yürütülmektedir. Süreç hakkında gerekli kararların ve önlemlerin herhangi bir gecikme olmadan tam zamanında alınması için sistemin gerçek zamanlı olarak izlenmesi ve kontrol edilmesi gerekmektedir. Üretim süreçlerinde meydana gelebilecek bir gecikme yüksek maliyetlere ve zaman kaybına neden olabilmektedir. Geleneksel makine öğrenmesi yöntemlerine kıyasla, verilerden otomatik özellik çıkarma yeteneğine sahip derin öğrenme yöntemleri üretim süreçleri gibi anında müdahale gerektiren alanlardan elde edilen büyük miktardaki verilerin gerçek zamanlı işlenebilmesini sağlamaktadır. Bu nedenle bu çalışmada önerilen zeki seru üretim sistemi modelinin her bir bileşenini gerçek zamanlı olarak izlemek ve kontrol etmek için derin öğrenmeye dayalı bir sistem mimarisi geliştirilmiştir. Önerilen zeki seru üretim sistemi modelinde Şekil 3.1’de gösterildiği gibi, Endüstri 2.0’deki atölye tipi üretimin yüksek esnekliğini, montaj hatlarının yüksek verimliliğini ve Toyota Üretim Sisteminin yalın felsefesini Endüstri 3.0’da birleştiren Seru Üretim sistemine, Endüstri 4.0’da IoT ve akıllı cihazlar ile izlenebilirlik, ağ altyapısı ile bağlanabilirlik, derin öğrenme ve diğer makine öğrenmesi algoritmaları ile ileri analitik, bulut teknolojisi ile depolanabilirlik, artırılmış gerçeklik ile sanallaştırma, raporlama araçları aracılığıyla karar verme becerileri özellikleri ilave edilerek Zeki Seru Üretim Sistemi modelinin geliştirilmesi amaçlanmaktadır. Bu teknolojilerin önerilen kavramsal model içerisindeki görev ve rolleri zeki seru üretim sistemi mimarisinin detaylarının verildiği Bölüm 3.2’de açıklanacaktır. Bu tez çalışmasında, Yin ve ark. (2018a) ’nin çalışmalarında sunmuş oldukları öneriler ışığında, seru üretim sistemine Endüstri 4.0 müşteri taleplerinin gerekliliklerini yerine getirebilecek şekilde yeni teknolojiler entegre edilerek, hem müşteri, tedarikçi, üretim ortamı bilgi ağını ve etkileşiminin gerçekleştirilmesi, hem de uygun tedarik zinciri kararlarının yönetimine destek olması planlanmaktadır. Aynı zamanda, üretim sürecinde çalışanların,

proseslerin ve üretim ortamının izlenmesi ve kontrolünün sağlanması amaçlanmaktadır.



Şekil 3.1. Zeki seru üretim sistemi.

Bu bölümde, önerilen modelin bileşenleri ve her bir bileşende kullanılan derin öğrenme tabanlı zeki izleme ve kontrol sistemi mimarisi açıklanmaktadır.

3.1. Zeki Seru Üretim Sistemi Modelinin Ana Bileşenleri

Zeki seru üretim sisteminin izlenmesi ve kontrolü için, derin öğrenmeye dayalı insan aktivite tanıma, nesne tespiti / izleme, zaman serisi tahmini, duruş analizi, iç ortam kalite analizi, tahmin / sınıflandırma, teslim süresi tahmini, çalışan performans değerlendirmesi uygulamalarını gerçekleştirecek aşağıdaki altı ana bileşen önerilmektedir;

- Montaj İşlemlerinin İzlenmesi ve Kontrolü,
- Montaj Ortamının İzlenmesi ve Kontrolü,
- Ürün Bileşenleri ve Montaj Araçlarının İzlenmesi ve Kontrolü,
- Kapasite ve Performansın İzlenmesi ve Kontrolü,
- Depolama / Envanterin İzlenmesi ve Kontrolü,
- Ergonomi ve Güvenliğin İzlenmesi ve Kontrolü.

Bileşen 1- Montaj İşlemlerinin İzlenmesi ve Kontrolü: Üründeki kalite hatalarının ve üretim planlarının istenilen düzeyde gerçekleştirilememesinin en büyük sebebi montaj süreçlerindeki hatalardan kaynaklanmaktadır. Seru üretim, bir ürünün montajı için gerekli görevlerin tamamının bir çalışan tarafından bir yatai içerisinde gerçekleştirilmesini gerektirir. Bu da çalışanların çapraz eğitimi ile sağlanır. Her bir montaj süreci, iki temel amaç için gerçek zamanlı olarak izlenir: işçileri montaj görevleri için desteklemek ve süreçte düzeltmek amacıyla olası bir hatayı veya faaliyet uygunsuzluğunu gerçek zamanlı tespit etmek.

Bileşen 2- Montaj Ortamının İzlenmesi ve Kontrolü: Sıcaklık, nem, gürültü, titreşim, aydınlatma, karbon monoksit (CO) konsantrasyonu, karbondioksit (CO₂) konsantrasyonu, toz seviyeleri, toksisite gibi fiziksel çalışma ortamı faktörlerinin etkisi çalışanların morali ve çalışma kabiliyetleri üzerinde çok önemlidir (Jagdale ve ark, 2015). Bu faktörler sadece çalışanların performansını etkilemekle kalmaz, aynı zamanda iş kazaları ve meslek hastalıkları gibi iş güvenliği açısından da önemli bir yer teşkil eder. Bu nedenlerden dolayı, bu hayati parametreleri kontrol etmek için seru sistem ortamı sürekli izlenmelidir. Çalışma ortamı için izleme, değerlendirme ve kontrol gereklidir. Bu alanda derin öğrenmeye dayalı iç ortam kalitesi analiz modellerinden faydalanılmasıyla çalışma ortamının ergonomik açıdan uygun olması sağlanır, dolayısıyla çalışanın performansının geliştirilmesi ve firmanın verimliliğinin artırılması sağlanabilir.

Bileşen 3- Ürün Bileşenleri ve Montaj Araçlarının İzlenmesi ve Kontrolü: Seru üretim sisteminde kanketsu prensibinin gerçekleştirilebilmesi için tüm kaynakların seru içerisinde erişilebilir olması gerekmektedir. Bu yüzden montaj işlemlerinin verimli bir şekilde gerçekleştirilmesi, ürün bileşenlerinin ve montaj araçlarının izlenerek eksiksiz bir şekilde doğru yerlerinde bulunmasına bağlıdır. Bu şekilde montaj ekipmanlarının ve parçalarının gereksiz ve hatalı kullanımının önüne geçilebilir. Malzemelerin eksiksiz olmalarını sağlamak beklentileri azaltırken, doğru yerlerinde olmalarını sağlamak ise gereksiz hareketleri ve dikkat dağınıklığını önler. Bu amaçla, derin öğrenme tabanlı nesne tespiti ve nesne izleme modelleri kullanılabilir.

Bileşen 4- Kapasite ve Performansın İzlenmesi ve Kontrolü: Seru üretim sistemi insan merkezli olduğu için birçok faktörden dolayı çalışanların montaj operasyon süreleri dinamiklidir. Üretim planlama ve çizelgelemenin doğru bir şekilde yapılabilmesi ve geliştirilen plan ve çizelgelerin gerçekleşme durumlarının belirlenmesi için üretim

süreçleri ve programları gerçek zamanlı olarak izlenmeli ve kontrol edilmelidir. Seru üretim sistemindeki çalışanlar beceri düzeylerine göre derecelendirilir. Montaj süreçlerinin izlenmesi ve kontrolü ile çalışanların beceri seviyeleri gerçek zamanlı olarak belirlenebilir. Üretim performansları, öğrenme performansları ve kendini geliştirme performansları değerlendirilebilir. Bu da çalışanların hangi ürünlerin montajında ne kadar yetenekli oldukları, beceri seviyelerini artırmak için ne kadar eğitilmeleri gerektiği hakkında bilgi verir. Sürece göre gerçek zamanlı olarak kendini güncelleyen model sayesinde üretim planlaması ve çizelgeleme daha gerçekçi hale getirilebilir.

Bileşen 5- Depolama / Envanterin İzlenmesi ve Kontrolü: Seru üretim sisteminde montaj süreçlerinin kesintisiz olmasını sağlamak için ürün bileşenlerinin montaj süreçleri boyunca erişilebilir olmalıdır. Bu nedenle yatailer içerisinde montaj yapılacak ürün bileşenlerinin kutular gibi belirli bir miktarda istiflendiği alanlar vardır. Diğer taraftan, montaj süreçleri biten ürünlerin depoya alınmayı beklediği alanlar da bulunmaktadır. Ancak bu alanlar sınırlı olduğu için gün boyu depolanma kapasitesine sahip olmayabilir. Bu nedenle belirli aralıklarla tüketilen ürün bileşenleri yataiye temin edilmeli, bitmiş ürünler yataiden toplanarak depolara getirilmelidir.

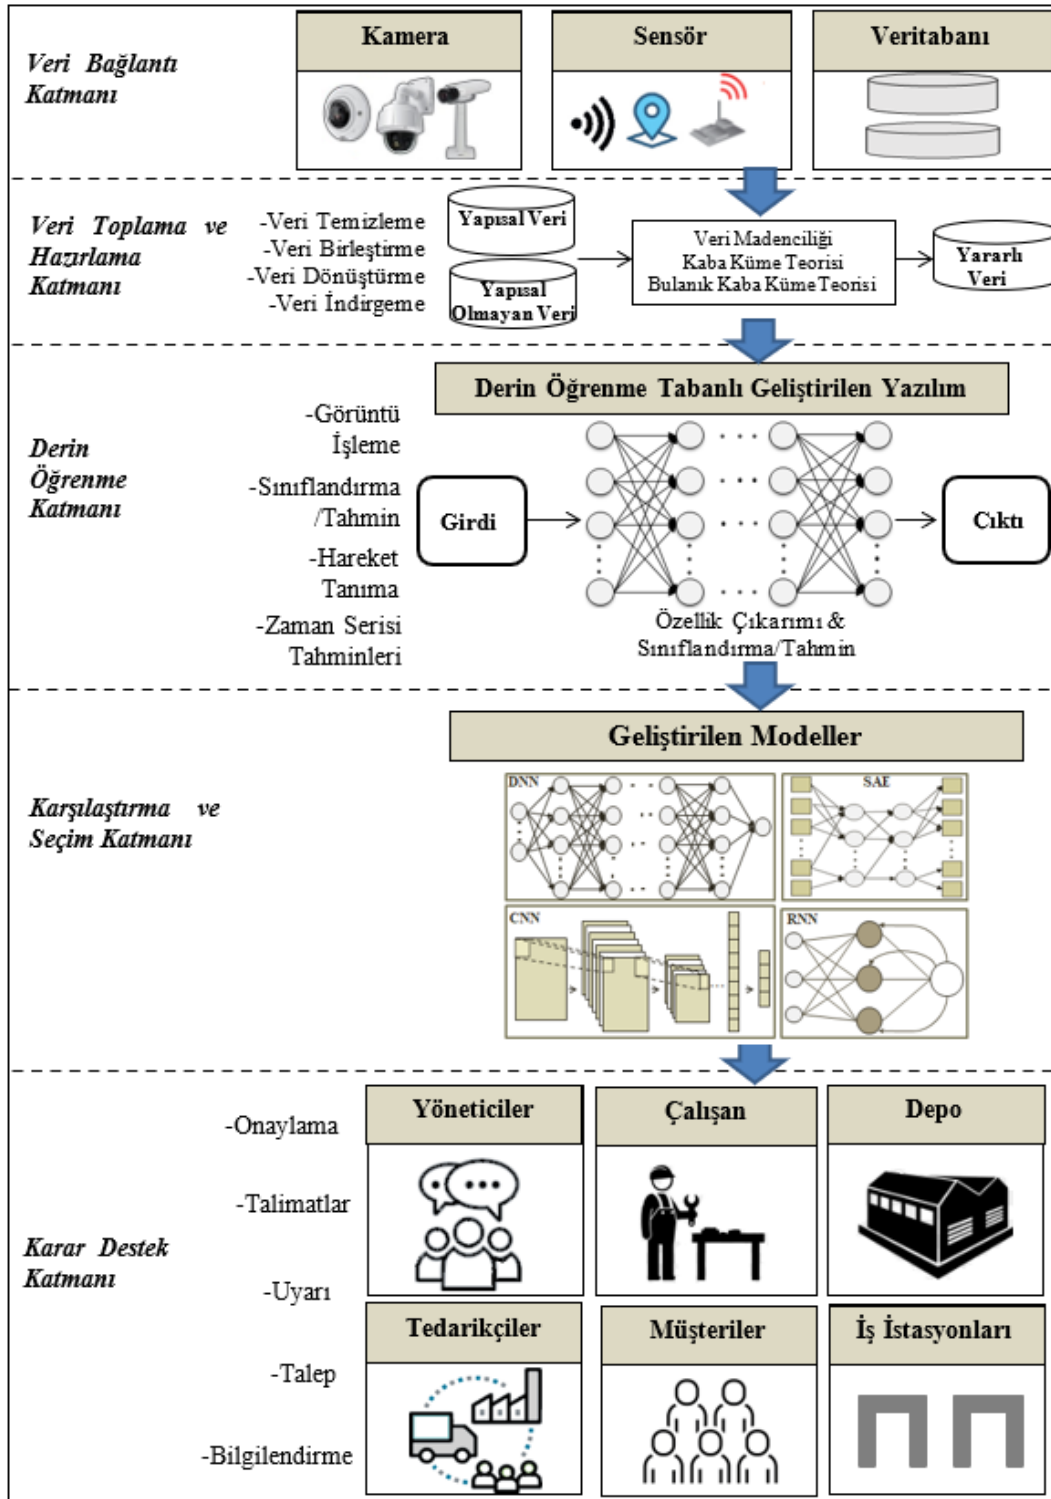
Bileşen 6- Ergonomi ve Güvenliğin İzlenmesi ve Kontrolü: Çalışanların seru üretim sisteminde montaj işlemlerini gerçekleştirdiği yatailerin tasarımı, montaj işlemlerinin kalitesi üzerinde önemli bir etkiye sahiptir. Uygun olmayan iş istasyonları sadece çalışanın verimini düşürmekle kalmaz, aynı zamanda çeşitli kas-iskelet sistemi rahatsızlıklarına da neden olabilir. Çalışanlar, garip duruşların neden olduğu omuz ağrısı, boyun ağrısı ve bel ağrısı gibi birçok sağlık sorunuyla karşılaşabilirler (Nishant ve ark, 2015). Diğer taraftan montaj görevleri, çalışanların fiziksel yeteneklerine göre ve çalışanın vücuduna fazla fiziksel baskı yapmadan görevi yerine getirebileceği şekilde tasarlanmalıdır (Nath, 2017). Çalışma ortamında kuvvet, tekrarlayan çalışma, garip duruşlar, hızlı hareket ve sıkıştırma gibi ergonomik ve sağlıkla ilgili risk faktörleri belirlenerek çalışanların morali ve üretkenliği artırılabilir ve devamsızlık azaltılabilir (Lakhal ve ark, 2017). Çalışanların fiziksel özelliklerinin uygun olduğu görevler belirlenebilir. Bu sayede çalışanların iş tatmini artar.

Sonuç olarak, önerilen zeki seru üretim sistemi altı bileşenden oluşmaktadır. Bu bileşenler seru üretim sistemi ile ilgili literatürde bahsedilen zorlukların üstesinden gelinmesi amacıyla tasarlanmıştır. Bu bölümde zeki seru üretim sistemi için önerilen

altı temel bileşen ve bu bileşenlere duyulan ihtiyaç hakkında bilgi verilmiştir. Önerilen sistemde her bir bileşenin temelinde derin öğrenme tabanlı zeki izleme ve kontrol sistemi mimarisi kullanılmaktadır. Bir sonraki bölümde önerilen bu zeki serü üretim sistemi mimarisinin detayları aktarılacaktır.

3.2. Zeki Serü Üretim Sistemi Mimarisi

Bu çalışmada, serü üretim sisteminde hata önlemek amacıyla, serü üretimindeki süreç ve kalite hatalarının önlenmesi için üretim sürecini izleyen ve kontrol eden, gerektiğinde uyarı veren derin öğrenmeye dayalı gerçek zamanlı kavramsal bir model önerilmiştir. Bir önceki bölümde belirtilen gereksinimlerden dolayı modelde nihai ürün, ürün bileşenleri, çalışan, süreç, envanter, ortam ve montaj araçları izlenmektedir. Derin öğrenme kullanılarak serü sisteminin izlenmesi ve kontrol edilmesi için önerilen sistem mimarisinin bir gösterimi Şekil 3.2'de verilmektedir. Model beş temel katmandan oluşur: veri bağlantı katmanı, veri toplama ve hazırlık katmanı, derin öğrenme katmanı, karşılaştırma ve seçim katmanı ve karar destek katmanı. Model, her serü üretim sistemi bileşenini izleyebilecek ve sistemle ilgili tüm gerekli bilgilere erişebilecek şekilde tasarlanmıştır. Veriler kameralar, sensörler ve veritabanları aracılığıyla toplanır. Bu bileşenlerle, montaj parçalarından, süreç içindeki iş öğelerinden, bitmiş ürünlerden, veritabanlarından, çalışanlardan ve ortamdaki veriler elde edilir. Bu şekilde, ilgilenilen öğeler kontrol edilebilirlik ve izlenebilirlik açısından geliştirilir. Elde edilen yapısal ve yapısal olmayan veriler, veri madenciliği, kaba kümeleme teorisi ve bulanık kaba kümeleme teorisi algoritmaları kullanılarak veri temizleme, eksik değer tamamlama, veri birleştirme ve örnek seçimi gibi veri ön işleme aşamalarından geçirilir. Bu, verilerin kalitesini artırır ve verileri kullanışlı hale getirir. Tanımlayıcı, tanısal, tahminleyici ve kurallayıcı analizler amacıyla elde edilen verileri işlemek için farklı parametrelere sahip farklı derin öğrenme modelleri kullanılmaktadır. Bu modellerin kullanımı ile görüntü işleme, sınıflandırma / tahmin, video analizi, zaman serisi tahmin çalışmaları yapılmaktadır. Üretilen modellerin sonuçları karşılaştırılarak en iyi performans gösteren modeller seçilir. Elde edilen sonuçlara göre yöneticiler, çalışanlar, depolar, tedarikçiler, müşteriler ve iş istasyonları gibi sistem katılımcılarına gerekli onaylama, talimat, uyarı, talep ve bilgilendirme verilmektedir.

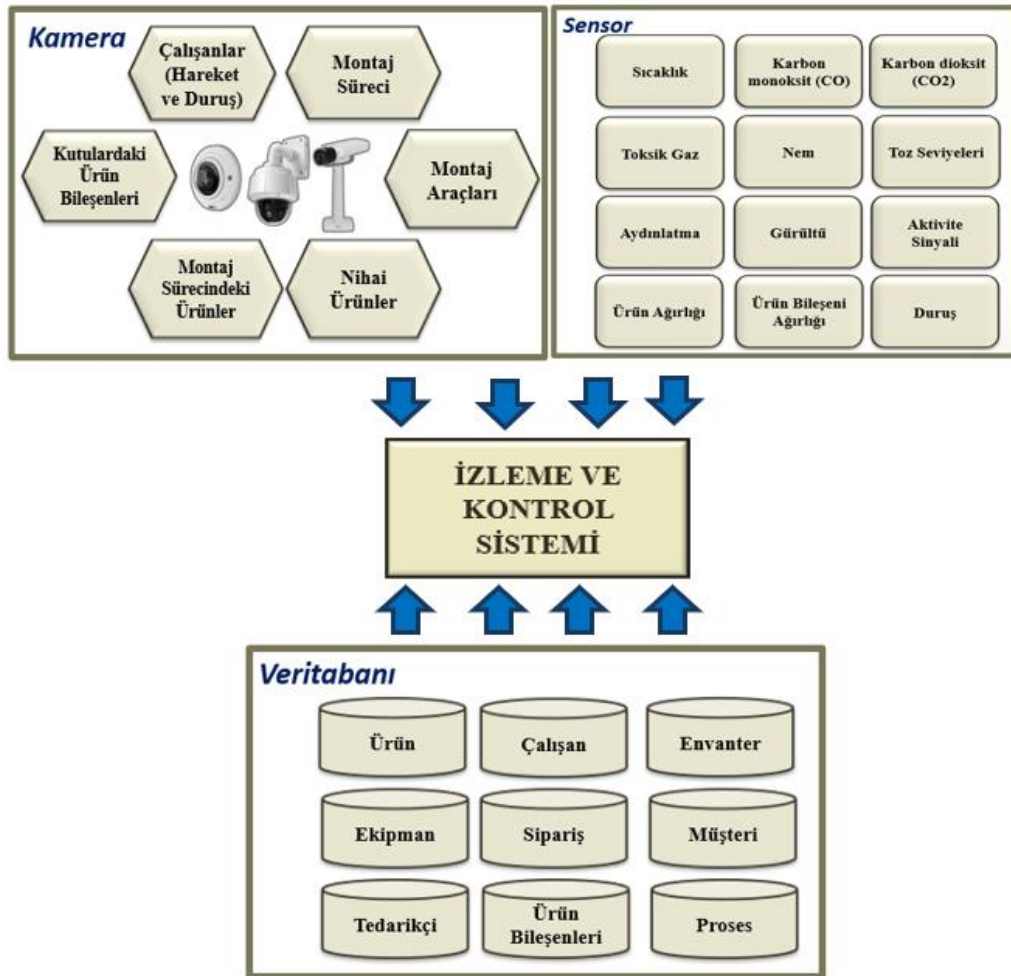


Şekil 3.2. Önerilen sistem mimarisi.

3.2.1. Veri bağlantı katmanı

Bilgi ve iletişim teknolojilerinin hızla gelişmesi, sensörler, kameralar, RFID'ler (Radyo Frekansı Tanımlama) gibi IoT teknoloji bileşenlerinin ortaya çıkmasını sağlamış ve bu teknolojilerin bağlantı ve iletişim yetenekleri sayesinde çok büyük miktarlarda gerçek zamanlı verileri elde etmek ve paylaşmak mümkün hale gelmiştir.

Bu teknolojilerin Wi-fi, Bluetooth, Zigbee, Z-wave, 4G LTE gibi ağ teknolojileri yardımıyla insan merkezli üretim sistemlerine entegrasyonu, fiziksel montaj sistemi ortamındaki ürün, ürün bileşenleri, montaj araçları ve çalışanlar gibi bileşenlerin sürekli bir ağını destekler ve veri analitiği için büyük bir fırsat sağlar. Bu bileşenlerden kapsamlı veri toplama, gerçek zamanlı izleme ve kontrol desteği ile hatasız montaj operasyonlarının gerçekleştirilmesine katkıda bulunur. Bu araçlar sayesinde montaj süreçlerinin tüm alanlarından elde edilen verilerin Kurumsal Kaynak Yönetimi (ERP), Üretim Yürütme Sistemi (MES), Müşteri İlişkileri Yönetimi (CRM) gibi yazılımlar aracılığıyla üretilen ve kurumsal veri ambarları veya bulutlar gibi veri kaynaklarında depolanan organizasyonun iş süreçleri ile ilgili geçmiş verilerle birleştirilmesiyle, verilerin analiz edilmesi ve gerçek-zamanlı karar vermede kullanılabilir hale gelmesi sağlanır. Çalışmada önerilen sistem mimarisinin veri bağlantısı bileşenleri Şekil 3.3’de verilmektedir.



Şekil 3.3. Veri bağlantısı bileşenleri.

Şekil 5.3'te gösterildiği gibi, önerilen sistem veri bağlantı katmanında 3 temel girdi bileşeninden beslenir: kameralar, sensörler ve veri tabanları. Kamera teknolojisi, montaj sürecindeki ürünlerin, nihai ürünlerin, kutulardaki ürün bileşenlerinin, montaj araçlarının, çalışanların (hareket ve duruş) ve montaj sürecinin görüntülerini ve video dizilerini sağlar. Ürün bileşenlerinden (ağırlık), çalışandan (aktivite sinyali, duruş, vücut eklem açıları, kasların elektriksel aktivitesi) ve ortamdan (sıcaklık, karbon monoksit, karbondioksit, toksik gaz, nem, toz seviyeleri, aydınlatma) veri toplamak için çeşitli sensör teknolojileri kullanılır. Kurumsal veri tabanlarından üretilen ürüne ait bilgiler, ürünü oluşturan bileşenlerin listesi, depodan yataiye gelen parçaların miktarı, depoda kalan parçaların miktarı, gün içerisinde üretilmesi gereken ürün miktarı, çalışanın geçmiş montaj operasyonları performansı ve tedarikçi bilgileri alınır. Bu katmanda veri elde edilecek bileşenler ile ilgili gerekli bağlantılar sağlandıktan sonra veri toplama ve hazırlama katmanı görevlerine geçilir.

3.2.2. Veri toplama ve hazırlama katmanı

Üretim süreçleriyle ilgili kaynaklardan elde edilen ham veriler genellikle eksik, gürültülü ve tutarsız olabilmekte ve analiz modellerinde doğrudan kullanılamamaktadır. Aksi takdirde bu verilerle oluşturulan modeller hatalı sonuçlar üretebilecektir. Verilerden anlamlı sonuçlar elde etmek, etkili modeller oluşturmak ve verimli tahmin sonuçları elde etmek için, modeller geliştirilmeden önce verilerin işlenmesi ve modele uygun yapıda, formatta ve yeterli miktarda olması sağlanmalıdır. Uygun veri toplama ve hazırlama teknikleri, verilerin kalitesini iyileştirir. Bu şekilde elde edilen kaliteli veriler, derin öğrenme modelleri sonuçlarının kalitesini artırır. Bu amaçla, istatistiksel yöntemlere ve veri madenciliği, kaba kümeleme ve bulanık kaba kümeleme algoritmalarına dayalı çeşitli veri hazırlama ve ön işleme teknikleri geliştirilmiştir. Şekil 3.4'te verildiği gibi, veri toplama ve hazırlama katmanı genel olarak sekiz temel adımdan oluşmaktadır; İş İhtiyaçlarını Tanımlama, Veri Seçimi ve Veri Toplama, Veriyi Anlama, Veri Ön İşleme, Veri Etiketleme, Veri Bölme, Veri Arttırma, Veri Seti Dengeleme.



Şekil 3.4. Veri toplama ve hazırlama adımları.

Veri hazırlama süreçlerinin ilk aşaması iş ihtiyaçlarının tanımlanmasıdır. Geliştirilen kavramsal modelin temel amaçları, üretim sürecini izlemek ve kontrol etmek ve serü üretiminde proses ve kalite hatalarının önlenmesi için sistem katılımcılarına uyarı vermektir. Bu hedefler doğrultusunda sistem; çevre, üretim bileşenleri, montaj ekipmanları, işlemler (operasyonlar), envanter ve ürün kalitesinin izlenmesini ve kontrolünü gerçekleştirir. Modellerin geliştirilmesi için gerekli veriler seçilir ve kameralar, sensörler ve veritabanları kaynaklarından toplanır. Veriyi anlama aşamasında, veri setindeki değişkenler belirlenir ve veriler geniş bir şekilde tanımlanır. Daha sonra değişkenler tek tek incelenerek veri tipi (metin veya sayısal), değer aralıkları ve değerlerin dağılımı gibi temel unsurlar kontrol edilmelidir. Değişkenler arasındaki ilişkiler analiz edilmeli ve veri setindeki potansiyel eğilimler belirlenmelidir. Veri setinin eksik, hatalı veri içerip içermediği ve modelleri oluşturmak için yeterli veri olup olmadığı kontrol edilmelidir.

Veri ön işleme aşamasında, veri setinin ihtiyaçlarına göre dört temel teknikler kümesi uygulanır: veri temizleme, veri birleştirme, veri dönüştürme, veri indirgeme. Veri temizleme adımında, eksik verilerin ele alınması, aykırı değerlerin belirlenmesi, gereksiz ve gürültülü verilerin elenmesi ve verideki tutarsızlıkların giderilmesi amaçlanmaktadır. Veri birleştirme teknikleri, farklı kaynaklardan gelen verileri birleştirir. Veri dönüştürme, çarpıklığı ele almayı, normalizasyonu, yumuşatmayı, görüntüleri yeniden boyutlandırmayı ve ayırıklaştırmayı içerir. Çok yüksek boyutlu

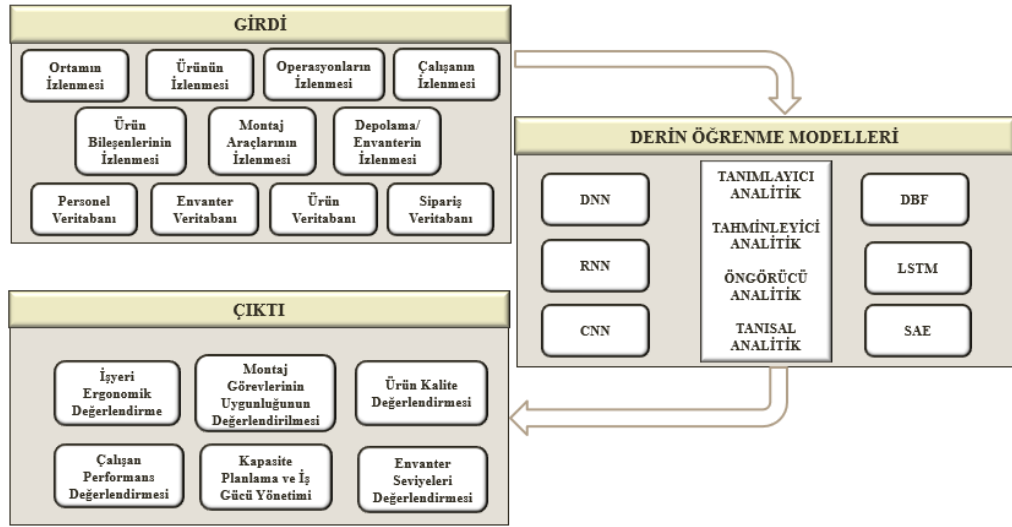
veriler, derin öğrenme modellerinin etkin bir şekilde geliştirilmesini engeller ve modellerin eğitim süresini artırır. Veri indirgeme aşamasında, veri örnekleme, boyut indirgeme ve örnek seçimi yöntemleri kullanılmaktadır. Denetimli öğrenme modelleri için eğitim veri setleri etiketlenmelidir. Veri etiketleme işlemleri manuel olarak veya bir araç veya yazılım kullanılarak gerçekleştirilebilir. Geliştirilen modellerde aşırı uyum sorununu önlemek ve modellerin genelleme yeteneğine sahip olmalarını sağlamak için veri bölme yöntemleri kullanılır. Veri seti, geliştirilecek modelin eğitimi için eğitim veri seti ve modelin performansını ölçmek için test veri seti olmak üzere iki gruba ayrılır.

Doğruluğu artırma hedefiyle derin öğrenme modellerinin etkili bir şekilde eğitimi için, çok sayıda parametreye sahip olması nedeniyle yüksek miktarda veri gerekmektedir. Yetersiz eğitim verisi sorununun üstesinden gelmek için, görüntü ve video veri setleri, veri artırma teknikleri kullanılarak sentetik olarak değiştirilir. Çok büyük derin öğrenme modellerini eğitmek için veri artırmanın kullanılması, aşırı uyum sorunlarıyla başa çıkma ve güvenilir veri eksikliğinden kaynaklanan genelleme hatalarını iyileştirme yeteneği verir. İncelenen veri setinde tahmin edilmesi istenen her bir sınıf tipine ait örnek sayısı dengesiz bir dağılıma sahip olduğunda, dengesiz veri seti durumu ortaya çıkmaktadır. Bu probleme çözüm üretmek için veri setini dengeleme aşamasında aşırı örnekleme, alt örnekleme, SMOTE (Sentetik Azınlık Örnekleme Arttırma Yöntemi) ve sentetik veri üretimi gibi yöntemler kullanılmaktadır. Veri toplama ve hazırlama katmanında işlenmeye hazır hale getirilen veriler, uygun modellerin geliştirilmesi amacıyla derin öğrenme katmanına gönderilir.

3.2.3. Derin öğrenme katmanı

Seru üretim sisteminde üretilen verilerin dinamik ve daha bilgiye dayalı karar verme süreçleri sağlamak ve montaj sistemlerinin performansını iyileştirmek için analiz edilmesi gerekmektedir. Şekil 3.5'te derin öğrenme katmanındaki girdiler, derin öğrenme modelleri ve çıktılar verilmektedir. Değişken müşteri taleplerine hızlı cevap verebilmek için gerçek zamanlı izleme ve kontrol, montaj sistem bileşenlerinin ve bunları etkileyen faktörlerin durum tespiti, montaj ortamındaki anormalliklerin tespiti, sistem performansının değerlendirilmesi, ürün kalitesinin iyileştirilmesi, montaj süreçlerinde hataların meydana gelmeden önce önlenmesi ve geleceğe yönelik eylemlerin belirlenmesi için gelecekteki geliştirilmiş veriye dayalı teknikler için eylemlerin belirlenmesi için gelişmiş veri odaklı teknikler gerekmektedir. Derin

öğrenme, sensörlerden, kameralardan ve kurumsal veritabanlarından yakalanan verilerden faydalı bilgiler çıkarmak için veri analizi modelleri ve algoritmaları içeren gelişmiş bir teknolojidir.



Şekil 3.5. Derin öğrenme katmanı.

Derin öğrenme katmanında en doğru analiz sonuçlarına göre karar verilebilmesi amacıyla farklı parametrelere sahip farklı derin öğrenme modelleri geliştirilmektedir. Her model, gerekli analiz türünün gereksinimlerine ve incelenen veri setinin özelliklerine uyacak şekilde yapılandırılır. Derin öğrenme modellerinin geliştirilmesindeki ilk adım, desteklenen iş kararlarını sağlamak için hedeflenen çıktıları ve bu çıktıları elde etmek için kullanılacak girdileri belirlemektir. Derin öğrenme modelleri, tanımlayıcı analitik, tanısal analitik, tahminleyici analitik, öngörücü analitik dahil olmak üzere çeşitli büyük veri analitiği için kapsamlı bir araç olarak hizmet eder.

- Tanımlayıcı Analitik: Süreçleri iyileştirmek ve geleceğe yönelik tahminlere dayalı kararlar almak için mevcut durumları ve geçmiş davranışları iyi anlamak esastır. Bu, sistemin fırsatları ve zorlukları hakkında fikir verir. Tanımlayıcı analitik, “Ne oldu?” ve “Ne oluyor?” sorularının yanıtlarını araştırır.
- Tanısal Analitik: Kalite hataları meydana geldiğinde veya istenilen performansa ulaşılamadığında, bu durumlarla baş edebilmek ve serü üretim sisteminin istenmeyen durumlarını ortadan kaldırabilmek için hataların sebepleri araştırılmalı ve tespit edilmelidir. Tanısal analitik, “Neden oldu?” sorusunu yanıtlamaya yardımcı olur.

- Tahminleyici Analitik: Tahmine dayalı analitik, geçmiş verilere dayalı olarak gelecekteki eğilimleri tahmin eden bir dizi yaklaşım ve tekniktir. Gelecekte ne olacağı ile ilgili soruları yanıtlamaya yardımcı olur.
- Öngörücü Analitik: “Bundan sonra ne yapılmalı?” sorusunu yanıtlamak için verileri inceler. Sistemin performansını artırmak ve kalite hatalarını önlemek için tüm sistem düşünülerek geleceğe yönelik aksiyon planları sunulur.

Bu katmanda geliştirilen çeşitli derin öğrenme modelleri, sistem bileşenine en uygun modelin belirlenmesi amacıyla karşılaştırma ve seçim katmanına gönderilir.

3.2.4. Karşılaştırma ve seçim katmanı

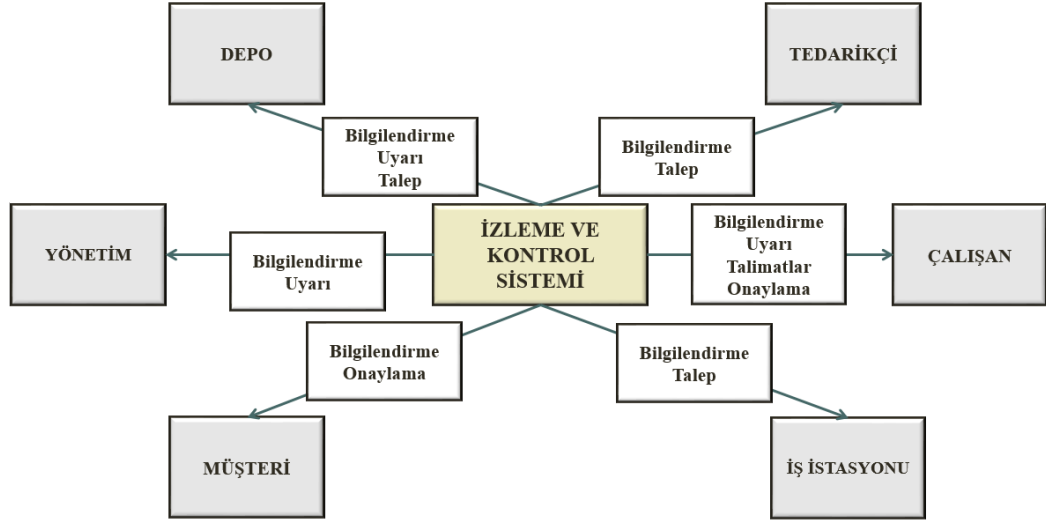
Derin öğrenme modelleri oluşturmanın amacı, modellerin genelleme yeteneğine sahip olmasıdır, yani sadece eğitildikleri veri setinde değil, daha önce hiç görmedikleri verilerde de iyi bir performans gücüne sahip olmalarıdır. Sınama seti (hold-out) ve çapraz doğrulama (cross-validation), çeşitli model değerlendirme yöntemlerinden bazılarıdır. Sınama seti yönteminde orijinal veri seti rastgele eğitim ve test veri setine bölünür. Model, eğitim veri seti ile eğitilir ve modelin performansı, test veri seti ile değerlendirilir. Çapraz doğrulama yönteminde, veri setinin K-katlı bölümleri oluşturulur. K deneylerinin her biri için, eğitim için K-1 bölümleri kullanılır ve geri kalanı test için kullanılır (Diren ve Boran, 2021). Veri seti yeterince büyükse sınama seti yöntemi, veri kümesi küçükse çapraz doğrulama yöntemi kullanılır.

Seru sisteminde hataları önlemek ve verimliliği artırmak için doğru ve güvenilir veri analizlerine dayalı kararlar alınmalıdır. Bu nedenle, derin öğrenme katmanında geliştirilen farklı parametrelere sahip farklı derin öğrenme modelleri performans ölçütlerine göre karşılaştırılır ve her uygulama için en iyi performans gösteren model seçilir. Analiz türlerine göre farklı değerlendirme ölçütleri kullanılmaktadır. Regresyon modelleri için ortalama mutlak hata (MAE), hata kareleri ortalaması (MSE), ortalama mutlak yüzde hata (MAPE), hata kareleri ortalamasının kökü (RMSE), belirleme katsayısı (R^2) gibi değerlendirme ölçütleri kullanılırken (Yaşar ve ark, 2021), sınıflandırma modelleri için sınıflandırma doğruluğu, kesinlik, duyarlılık, F1-Skor kullanılabilir (Mehmood ve ark, 2021).

Bu katmanda en iyi performansı gösteren derin öğrenme modeli seçildikten sonra model sistem katılımcılarına gerekli bildirimlerin sağlanabilmesi için karar destek katmanına gönderilir.

3.2.5. Karar destek katmanı

Belirsiz piyasa koşullarında rekabet avantajı elde etmek amacıyla gerçek zamanlı yanıtlar için dinamik ve merkezi olmayan karar verme gereklidir. Firmalar, üretim sistemine bütüncül bir bakış açısı kazandırarak doğru kararlar verebilmek için veri toplamalı ve analiz etmelidir. Şekil 3.6'da görüldüğü gibi önerilen sistemin karar destek katmanında, derin öğrenmeye dayalı gelişmiş analitik sonuçları sayesinde yöneticiler, çalışanlar, depolar, tedarikçiler, müşteriler, iş istasyonları gibi sistem katılımcılarına gerekli onaylama, talimatlar, uyarı, talep ve bilgilendirme sağlanmaktadır. Seru üretim sisteminin gerçek zamanlı izlenmesi ve kontrolü ile kalite hataları oluşmadan önlenir. Ayrıca verimlilik artışı, bekleme ve israfın azalması, çalışanın ve sistemin performansının artması, kaynakların verimli kullanılması, dalgalı müşteri talebine ayak uydurulması sağlanabilir.



Şekil 3.6. Sistem katılımcıları için karar destek katmanı.

Modeller aracılığıyla elde edilen uyarılar sistem katılımcılarına e-posta, bildirim, mesaj şeklinde gönderilebilir, sistem katılımcıları bu uyarılara tablet veya mobil cihazlardan ulaşarak anında aksiyon alabilirler. Montaj görevlerinin doğru bir şekilde nasıl gerçekleştirileceği ve çalışan hataları artırılmış gerçeklik ile çalışanlara bildirilir. Kurumsal Kaynak Yönetim Sistemi ile çalışanlar, iş istasyonları, veri ambarları ve yöneticiler bilgilendirilebilir. Tedarik Zinciri Yönetimi, Müşteri Kaynakları Yönetimi gibi harici arayüzler ile tedarikçiler ve müşteriler modellerin çıktılarını hakkında bilgilendirilebilirler. Sistem katılımcılarının karar vermelerine yardımcı olmak için raporlar, gösterge tabloları ve bildirim sayfaları içeren bir kullanıcı arayüzü geliştirilir.

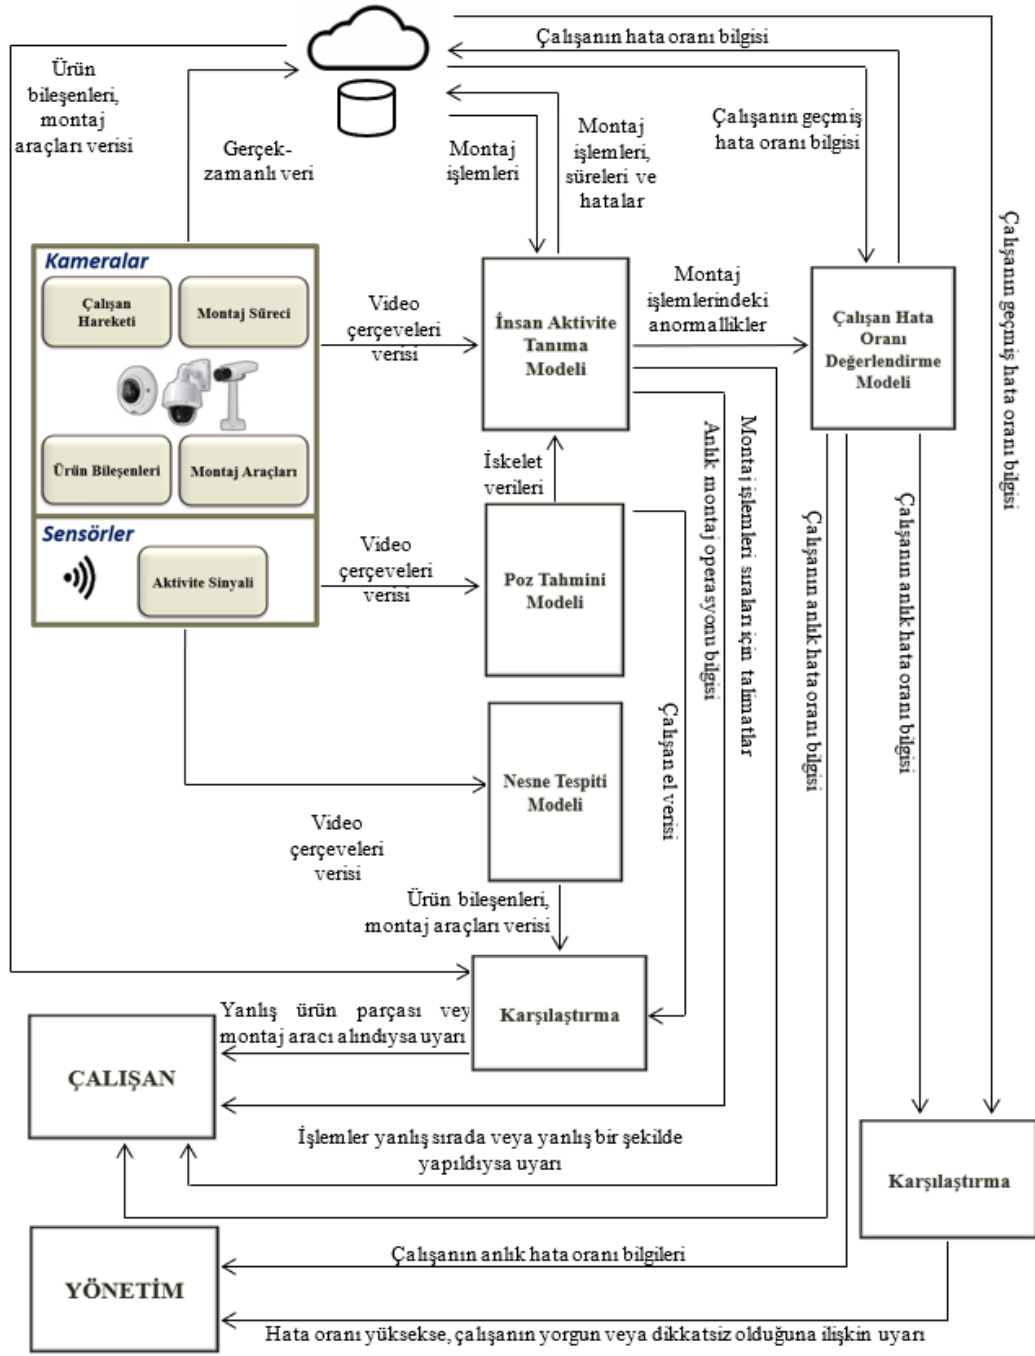
Kullanıcılar, bir mobil uygulama veya bir tablet veya kişisel bilgisayar aracılığıyla bir web tarayıcısı aracılığıyla uygulamaya proaktif olarak giriş yapabilir.

3.3. Zeki Seru Üretim Sistemi Bileşenlerinin Detayları

Her bileşenin temelinde, Bölüm 3.2'de açıklanan mimari bulunmaktadır. Bileşenler bu mimariye uygun olarak inşa edilir ve eşzamanlı çalışması sağlanır. Sistem bileşenleri birbirleriyle etkileşim halindedir. Bu bölümde zeki seru üretim sistemi bileşenlerinin çalışma yapısı açıklanmaktadır.

3.3.1. Montaj İşlemlerinin İzlenmesi ve Kontrolü

Seru üretim sisteminde, yatailer kendi kendine öğrenen organizasyonlardır. Ancak deneyimsiz işçiler seru üretim sistemine dahil edildiğinde sistem verimliliği düşebilir. Montaj işlemlerinin izlenmesi ve kontrolü bileşenin çalışma yapısı Şekil 3.7'de gösterilmektedir. Çalışanın eylemleri, derin öğrenmeye dayalı insan aktivite tanıma modelleri yardımıyla tanınır. Veritabanından ürünün montajı için gerekli montaj işlem sıraları alınır ve sırasıyla gerçekleştirilecek işlem talimatları hakkında çalışanlar arttırılmış gerçeklik gözlüğü ile bilgilendirilir. Bu şekilde, çalışanlar farklı ürün türlerine kolayca uyum sağlayabilir ve çalışanların yeni ürün türlerini bir araya getirmeleri için eğitim süreleri kısılır. Ürün bileşenlerinin ve montaj araçlarının görüntüleri kamera aracılığıyla alınır ve nesne tespiti ve nesne takip modelleri yardımıyla tanınır ve izlenir. Çalışan, işlemleri yanlış sırada yaparsa, işlemleri yanlış gerçekleştirirse veya yanlış bir ürün bileşeni veya montaj aleti alırsa, sistem tarafından çalışan uyarılır. Görevin nasıl yapılacağına dair talimatlar verilir.



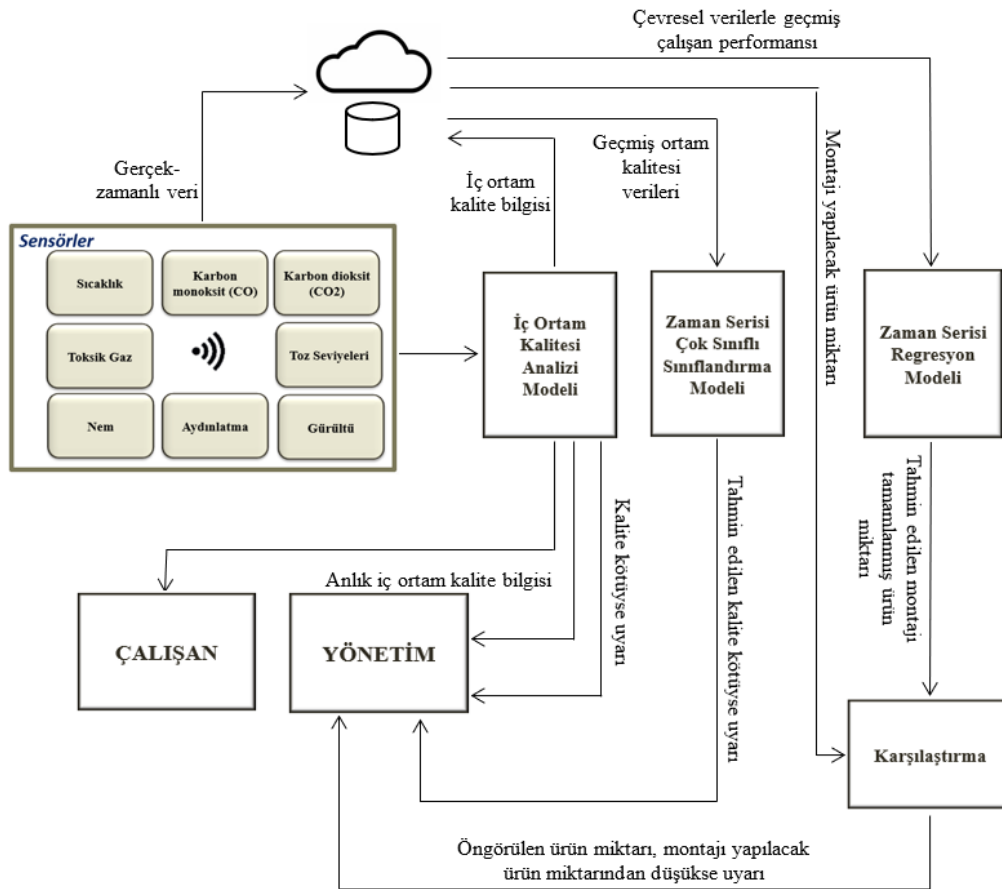
Şekil 3.7. Montaj İşlemlerinin izlenmesi ve kontrolü bileşeni diyagramı.

Montaj süreçlerinin izlenmesi yalnızca işin ilerlemesine yardımcı olmakla kalmaz, aynı zamanda çalışanların performansına ve bununla ilgili olası konulara ilişkin tahminlerde bulunulmasına olanak sağlar. Çalışanın geçmiş hatalarının mevcut durumdaki hata performansı ile karşılaştırılması dikkate alınarak, çalışanın hata oranı değerlendirilir. Yüksek ise yönetime çalışanın yorgun veya dikkatsiz olduğu bilgisi verilir. Bu şekilde montaj süreçlerinden kaynaklanan kalite hataları oluşmadan önlenmiş olur. Ayrıca yönetim, ürün durumu, mevcut çevrim süresi, çalışan üretim

performansı, çalışan kalite hata oranı, belirli bir zamandaki öğrenme ve kendini geliştirme oranı performansı hakkında bilgilendirilir. Çalışanların hata performansının izlenmesi, kendilerini geliştirmeleri için olumlu geribildirim sağlar.

3.3.2. Montaj ortamının izlenmesi ve kontrolü

Ortam iki açıdan incelenmektedir: montaj işlemleri için çalışma ortamının ergonomik uygunluğu ve mevcut çalışma ortamı koşulları altında çalışanın montajını tamamlayabileceği üretim miktarının tahmin edilmesi. Montaj Ortamının İzlenmesi ve Kontrolü bileşeninin şeması Şekil 3.8'de verilmiştir.



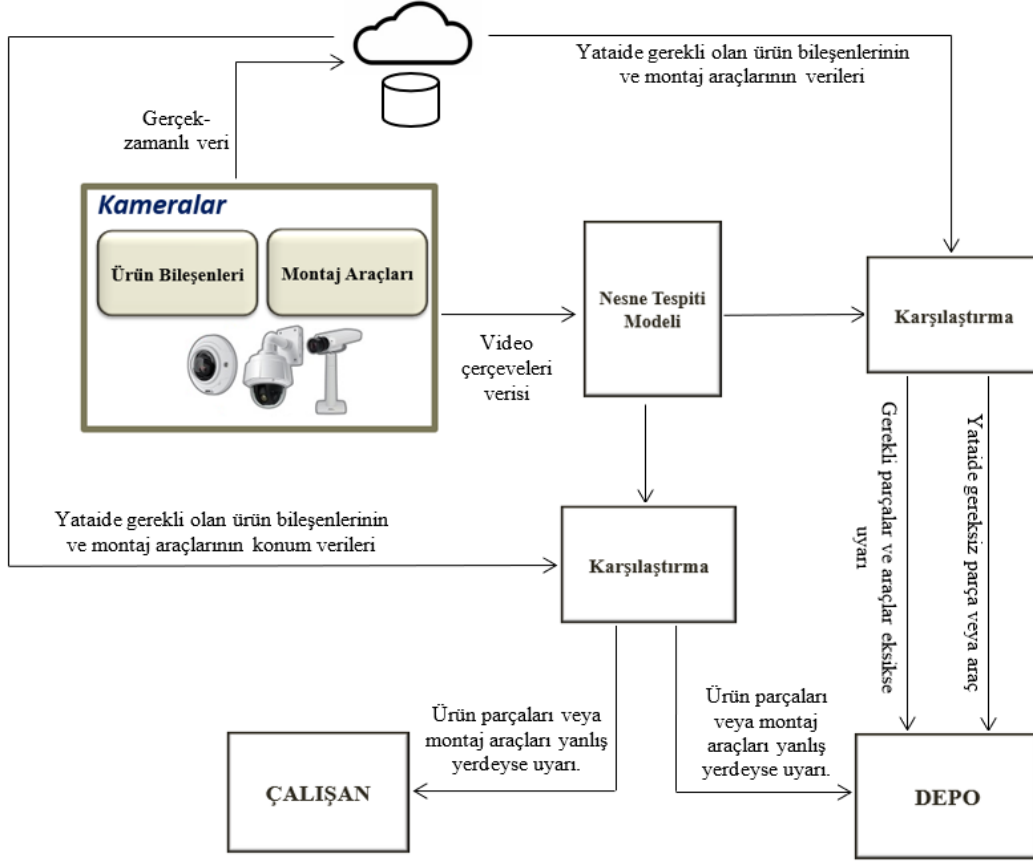
Şekil 3.8. Montaj ortamının izlenmesi ve kontrolü bileşeninin diyagramı.

Sensörlerden elde edilen gerçek zamanlı fiziksel çalışma ortamı faktörü bilgileri kullanılarak, çalışma ortamı kalitesi iyi-orta-zayıf olarak sınıflandırılır. Çalışanlar ve yöneticiler, çalışma ortamı hakkında gerçek zamanlı olarak bilgilendirilir. Mevcut iç ortam kalitesi ergonomi açısından operasyonlara uygun değilse yönetime uyarı gönderilir ve çevresel faktörlerin ayarlanması tavsiye edilir. Zaman serisi çok sınıflı sınıflandırma modeli yardımıyla, çalışma ortamının kalitesi geleceğe yönelik tahmin

edilir. Ortamın kalitesinin düşeceği yönünde tahmin oluştuğunda yönetime gerekli tedbirlerin alınması konusunda uyarı verilir. Çalışanın geçmişteki ortam şartlarına bağlı üretim miktarı bilgilerinden hareketle mevcut durumdaki ortam şartlarına bağlı montajını yapabileceği ürün miktarı tahmin edilir. Tahmin edilen ürün miktarı üretim planındaki ürün miktarının altına düşerse yönetime uyarı gönderilir. Bu şekilde, çalışma ortamının hem ergonomik açıdan hem de çalışanın planlanan üretim miktarını gerçekleştirmesine olanak sağlayacak şekilde uygun hale getirilmesi sağlanır.

3.3.3. Ürün bileşenlerinin ve montaj araçlarının izlenmesi ve kontrolü

Ürün bileşenlerinin ve montaj araçlarının izlenmesi ve kontrolü bileşeni diyagramı Şekil 3.9'da verilmiştir. Nesne tespiti, sınırlayıcı kutu koordinatlarını nesnelerin ait oldukları sınıfla birlikte döndürür. Üretilecek ürün, ürün bileşenleri ve gerekli montaj araçları ile ilgili bilgiler veri tabanından alınır. Kutulardaki ürün bileşenlerinin görüntüleri kamera aracılığıyla toplanır. Ürün bileşenleri görüntüleri, derin öğrenme tabanlı nesne tespiti yöntemleri ile analiz edilir ve ürün bileşenleri bilgileriyle karşılaştırılır. Gerekli bileşenlerin doğru kutularda olup olmadığı kontrol edilir. Aynı zamanda, ürünün montajının yapılması için gerekli ekipmanların görüntüleri de yatailerden alınır ve doğru yerde olup olmadığı kontrol edilir. Ürün bileşenleri ve gerekli montaj araçları eksikse veya yatai içerisinde yanlış yerlere yerleştirilmiş ise çalışana, yöneticiye ve depoya uyarı gönderilir.

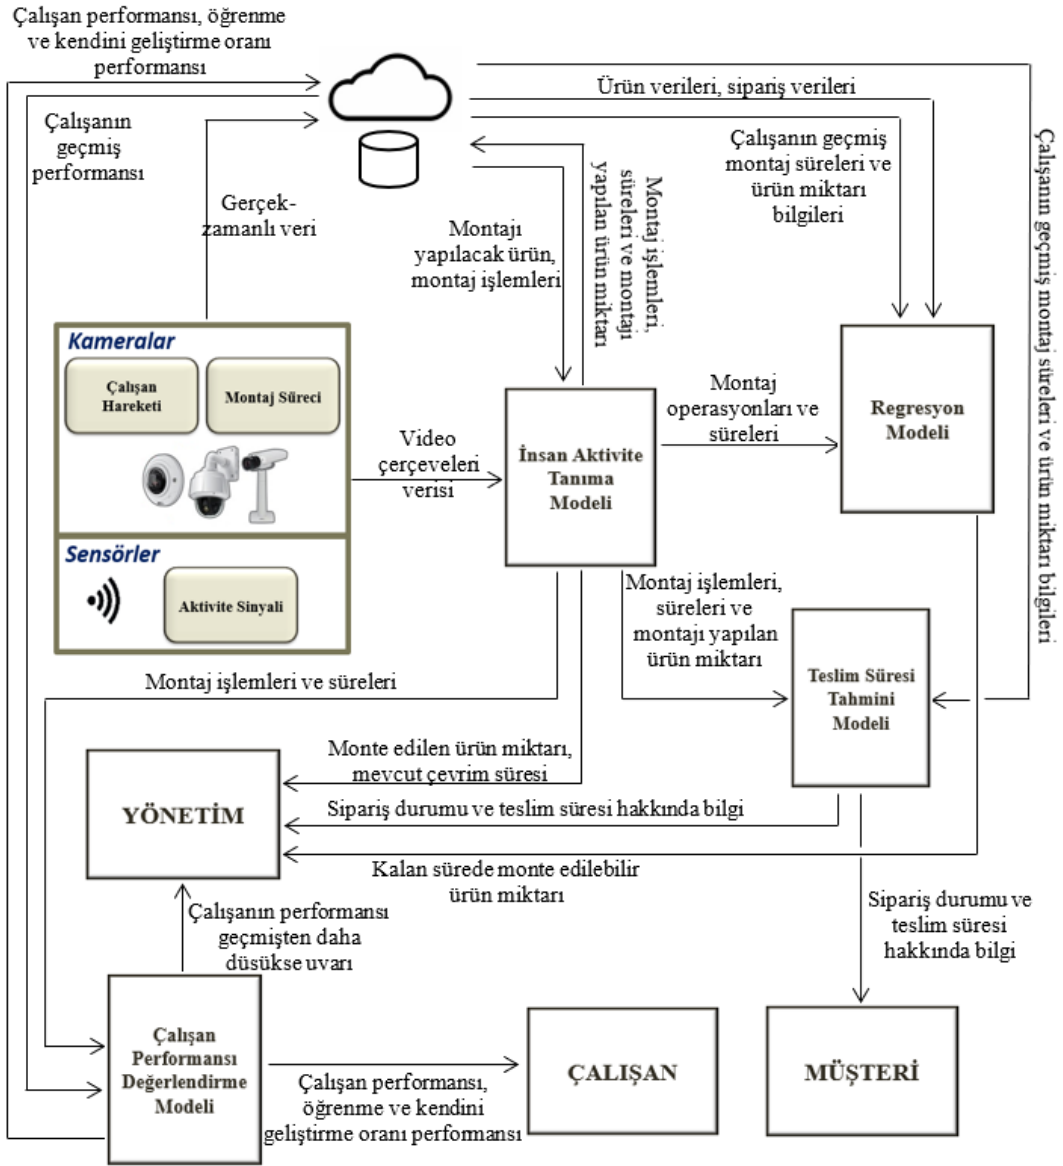


Şekil 3.9. Ürün bileşenlerinin ve montaj araçlarının izlenmesi ve kontrolü bileşeni diyagramı.

3.3.4. Kapasite ve performansın izlenmesi ve kontrolü

Kapasite ve performansın izlenmesi ve kontrolü bileşeninin çalışma yapısı Şekil 3.10'da verilmektedir. Çalışanın geçmiş montaj işlemleri süreleri veritabanından alınır. Mevcut çalışma gününde, çalışanın gerçek zamanlı montaj işlemi süreleri, derin öğrenme tabanlı eylem tanıma modelleri ile toplanır. Çalışanlar performansları hakkında bilgilendirilir. Çalışanın geçmiş üretim bilgilerinden yararlanılarak gün sonuna kadar kaç adet ürünün montajının yapılabileceği tahmin edilir. Kaç adet ürünün montajının yapıldığı ve kalan sürede kaç adet ürünün montajının yapılabileceği ile ilgili anlık bilgiler yönetime gönderilir. Müşteriler sipariş verdikleri ürünlerin durumu hakkında bilgilendirilir. Çalışanın mevcut çalışma günündeki gerçek zamanlı çalışma süreleri, geçmiş operasyon süreleri ile karşılaştırılır. Çalışanın geçmiş operasyon süreleri ve anlık işlem süreleri dikkate alınarak mevcut andaki performansı değerlendirilir. Düşükse yönetime yorgun veya dikkatsiz olduğu bilgisi verilir. Gün içerisinde gerekli üretim miktarına ulaşamayacağı tahmin edilirse, üretim yeniden programlanır ve diğer yatailer bilgilendirilir. Bu sayede yönetim, gerçek zamanlı

olarak kapasite planlaması ve iş gücü yönetimini gerçekleştirerek üretim sisteminin esnekliğinden yararlanabilir. Müşteriye ürün durumu hakkında bilgi verilir. Derin öğrenmeye dayalı teslim süresi tahmin modelleri ile müşteriye ne zaman teslim edilebileceği belirlenir.

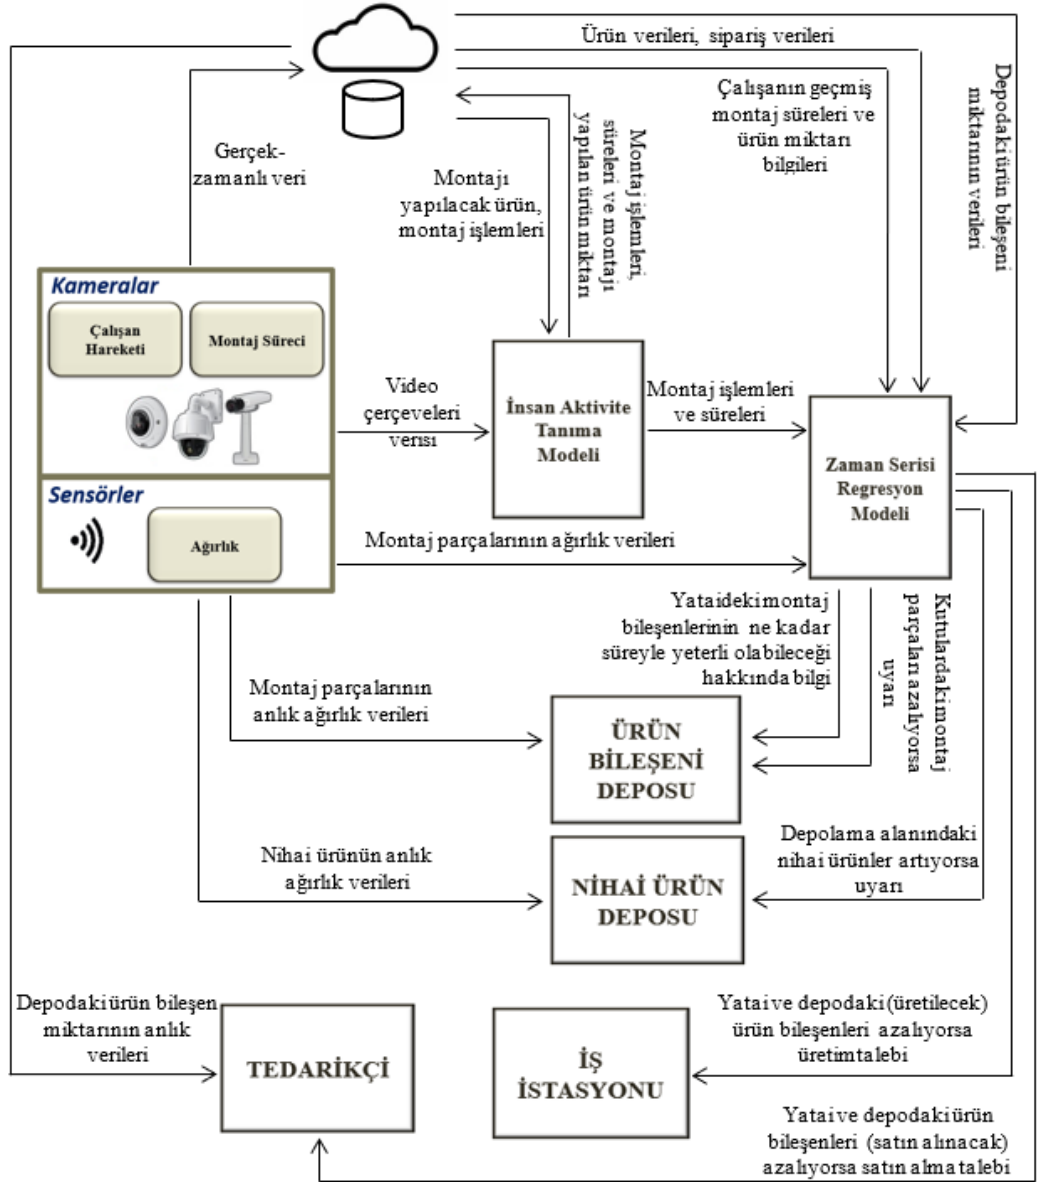


Şekil 3.10. Kapasite ve performansın izlenmesi ve kontrolü bileşeni diyagramı.

3.3.5. Depolama/envanterin izlenmesi ve kontrolü

Depolama / envanterin izlenmesi ve kontrolü bileşeninin diyagramı Şekil 3.11'de gösterilmektedir. Depolardan yataiye gelen parça (hammadde ve yarı mamul) sayısı, depolarda kalan parça miktarı, gün içinde üretilecek ürün miktarı bilgileri veritabanlarından alınır. Montaj parçalarının ağırlık bilgileri ağırlık sensörleri aracılığıyla toplanır. Süreçte kalan parça miktarı, ağırlık sensörü bilgileri ve montaj

parçası bilgilerinin ağırlığı kullanılarak hesaplanır. Anlık olarak depolara bildirilir. Derin öğrenmeye dayalı zaman serisi tahmin modelleri sayesinde montaj bileşenlerinin ne kadar süreyle yeterli olacağı tahmin edilir ve depolar bilgilendirilir. Sistem, yataideki montaj bileşenlerinin stoğu azaldığında depoya uyarılar gönderir. Yatai ve depolardaki parçalar ve gerçek zamanlı işçi performansı dikkate alınarak, montaj bileşenlerinin ne kadar süreyle yeterli olacağı tahmin edilir. Sürece göre gerçek zamanlı olarak kendini güncelleyen bu model sayesinde tedarikçiler ve iş istasyonları sürekli olarak bilgilendirilmektedir. Depolardaki montaj bileşenlerinin stok seviyeleri düştüğünde, yarı mamul üreten tedarikçi ve iş istasyonlarına uyarılar gönderilir. Depolar, yataideki nihai ürünün stok seviyesi hakkında bilgilendirilir. Stok seviyesi arttığında depolara uyarı gönderilerek yataiden ürünlerin alınması sağlanır. Envanter yönetimini, montaj süreçleriyle gerçek zamanlı işbirliği içinde yürütmek, tedarik zinciri yönetiminde verimliliği artırır.

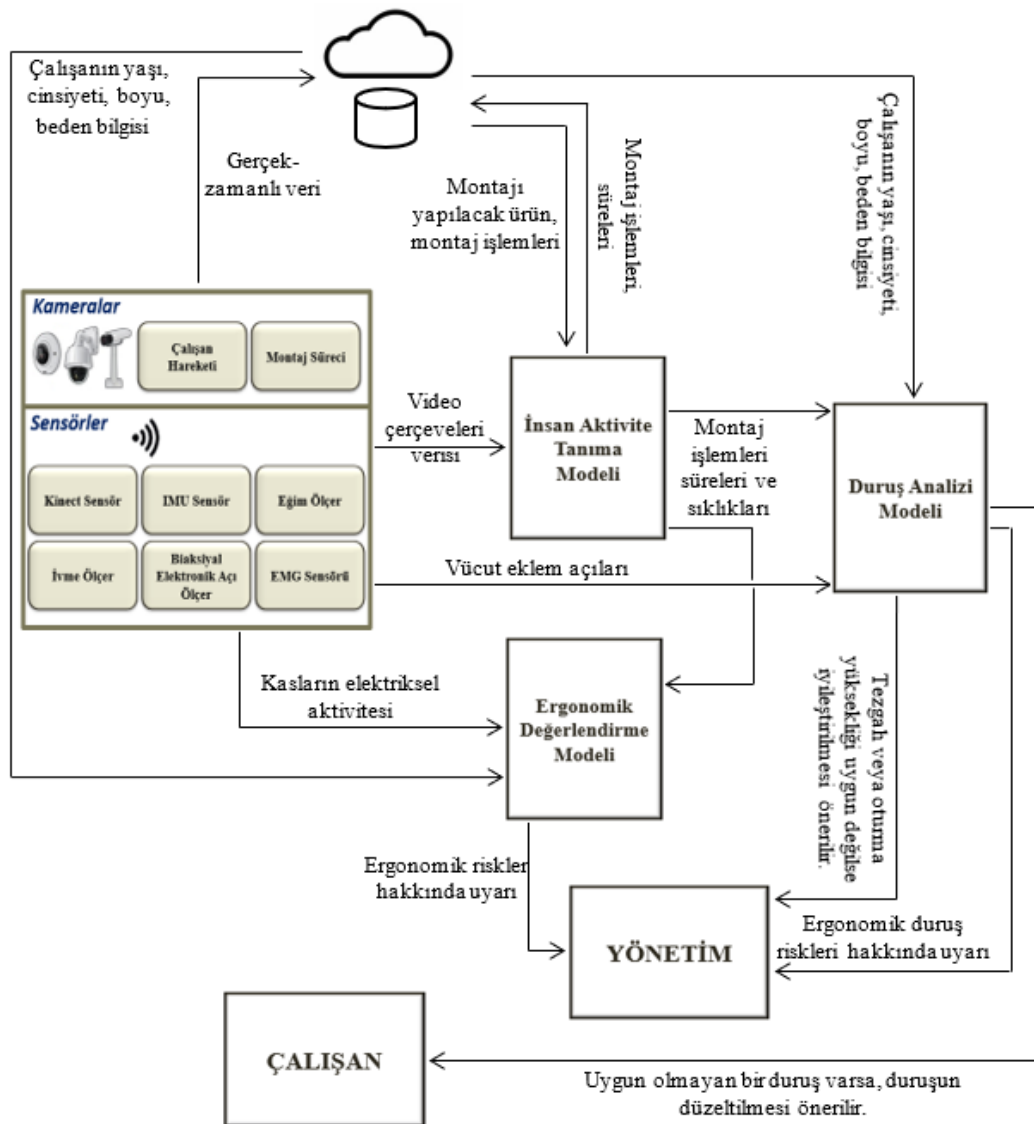


Şekil 3.11. Depolama /envanterin izlenmesi ve kontrolü bileşenin diyagramı.

3.3.6. Ergonomi ve güvenliğin izlenmesi ve kontrolü

Ergonomi ve güvenliğin izlenmesi ve kontrolü bileşeni (Şekil 3.12) için, çalışanların yaşı, cinsiyeti, kilosunu ve sağlık durumu ile ilgili bilgiler veri tabanından alınır. Kamera ile çalışan görüntüleri alınarak insan aktivite tanıma modelleri yardımıyla çalışma süreleri ve işlem sıklıkları belirlenir. Vücut eklem açısı bilgisi kamera ve sensörler ile alınır. Derin öğrenmeye dayalı duruş analizi modelleri yardımıyla çalışanlar analiz edilir ve çalışanın ve çalışma ortamının ergonomik uygunluğu değerlendirilir. Tezgah veya koltuk yüksekliği uygun değilse yönetime uyarı gönderilir. Uygun olmayan bir duruşta bulunuyorsa, çalışan gerçek zamanlı olarak artırılmış gerçeklik teknolojisi ile bilgilendirilir. Bu sayede çalışan duruşunu anında değiştirebilir. Diğer taraftan, geçmiş

duruş verileri ve üretim miktarı verileri (çalışan üretim performansı) veritabanlarında ve bulutta saklanır. Performansı en üst düzeye çıkarabilecek duruşlar ve duruşlardan kaynaklanabilecek tehlikeler, derin öğrenme tabanlı tahmin modelleri ile tahmin edilebilir. Gerçek zamanlı maruz kalma riski, çalışanların vücutlarına takılan sensörler kullanılarak ölçülür. Ergonomik iş yükleri, ergonomik değerlendirme modeli ile değerlendirilir. Riskli durumlar tespit edildiğinde aşırı fiziksel yüke neden olan uygunsuz durumların düzeltilmesi için yönetime ve çalışanlara uyarı gönderilir. Çok fazla güç gerektiren zorlu görevler belirlenir ve çalışanlar için uygun montaj araçları seçilerek ergonomik riskler önlenir.



Şekil 3.12. Ergonomi ve güvenliğin izlenmesi ve kontrolü bileşeninin diyagramı.

Bu tez çalışmasında serü üretim sistemine Endüstri 4.0 teknolojileri ilave edilerek sistemin gerçek zamanlı izlenmesi ve kontrol edilmesi için bir zeki serü üretim sistemi

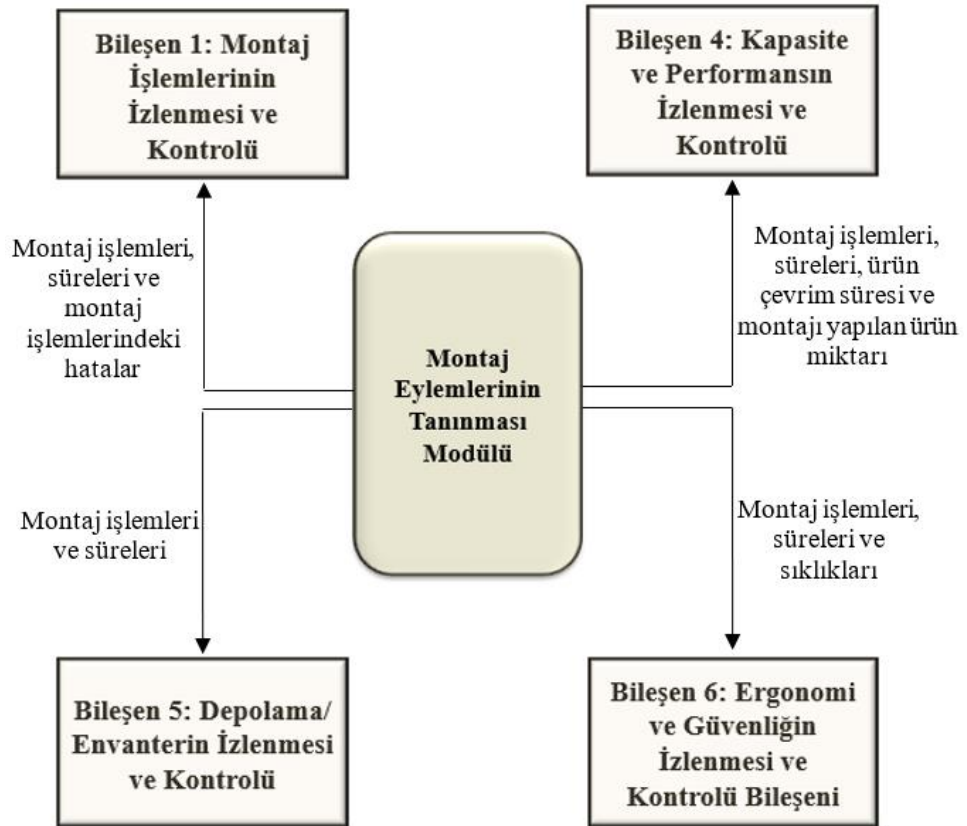
kavramsal modeli önerilmiştir. Sistem, Montaj İşlemlerinin İzlenmesi ve Kontrolü, Montaj Ortamının İzlenmesi ve Kontrolü, Ürün Bileşenleri ve Montaj Araçlarının İzlenmesi ve Kontrolü, Kapasite ve Performansın İzlenmesi ve Kontrolü, Depolama / Envanterin İzlenmesi ve Kontrolü ve Ergonomi ve Güvenliğin İzlenmesi ve Kontrolü olmak üzere altı bileşenden oluşmaktadır. Bileşenler literatürde serü üretim sistemi ile ilgili bahsedilen eksikliklerin ve ihtiyaçların giderilmesini hedefleyerek belirlenmiş ve tasarlanmıştır. Bu bölümde sistem bileşenlerinin gereklilikleri aktarıldıktan sonra her bir sistem bileşeni bünyesinde çalışacak olan derin öğrenmeye dayalı 5 katmanlı bir sistem mimarisi geliştirilerek detayları verilmiştir. Ardından, her bir bileşenin çalışma prensibi detayları açıklanmıştır. Görüldüğü üzere sistemin aşağıdaki dört bileşeninde ‘Montaj Eylemlerinin Tanınması Modeli’ görev almaktadır:

- Montaj İşlemlerinin İzlenmesi ve Kontrolü bileşeni,
- Kapasite ve Performansın İzlenmesi ve Kontrolü bileşeni,
- Depolama/Envanterin İzlenmesi ve Kontrolü bileşeni ve
- Ergonomi ve Güvenliğin İzlenmesi ve Kontrolü bileşeni.

Bu nedenle Montaj Eylemlerinin Tanınması modeli sistemin temel yapı taşlarından birini oluşturmaktadır. Bu tez çalışmasında zeki serü üretim sistemi için ‘Montaj Eylemlerinin Tanınması Modeli’nin metodolojisinin geliştirilmesi ve uygulamasının gerçekleştirilmesi hedeflenmiştir. Bir sonraki bölümde ‘Montaj Eylemlerinin Tanınması Modeli’nin dört bileşendeki görevleri açıklanmakta ve zeki serü üretim sistemi mimarisine uygun şekilde geliştirilen ‘Montaj Eylemlerinin Tanınması Modeli’ metodolojisi aktarılmaktadır.

4. MONTAJ EYLEMLERİNİN TANINMASI MODELİNİN GELİŞTİRİLMESİ

Bu bölümde, çalışmanın kavramsal modelinde önerilen Zeki Seru Üretim Sisteminin dört bileşenin bünyesinde bulunan ‘Montaj Eylemlerinin Tanınması Modeli’nin geliştirilmesi anlatılmaktadır. Montaj eylemlerinin tanınması modeli Şekil 4.1’de görüldüğü gibi ‘Montaj İşlemlerinin İzlenmesi ve Kontrolü’, ‘Kapasite ve Performansın İzlenmesi ve Kontrolü’, ‘Depolama/Envantere İzlenmesi ve Kontrolü’ ve ‘Ergonomi ve Güvenliğin İzlenmesi ve Kontrolü’ bileşenlerine gerekli olan verilerin elde edilmesi için montaj sınıfını belirlemektedir. Montaj eylemlerinin tanınması modeli sayesinde, Bileşen 1’de montaj işlemleri, süreleri ve montaj işlemlerindeki hatalar belirlenebilmekte iken, Bileşen 4’te montaj işlemleri, süreleri, ürün çevrim süresi ve montajı yapılan ürün miktarı, Bileşen 5’te montaj işlemleri ve süreleri, Bileşen 6’da ise montaj işlemleri süreleri ve sıklıkları belirlenebilmektedir.



Şekil 4.1. Montaj Eylemlerinin Tanınması Modeli.

Şekil 4.1’de akışları gösterilen verilerin elde edilmesi ile her bir bileşen için aşağıdaki amaçların gerçekleştirilmesi beklenmektedir.

‘Montaj İşlemlerinin İzlenmesi ve Kontrolü’ bileşeninde montaj eylemlerinin tanınması modeli sayesinde 4 temel işlev gerçekleştirilebilecektir:

- Gerçekleştirilen montaj eylemleri tespit edilerek çalışanın bir sonraki montaj eylemi hakkında bilgilendirilmesi,
- Gerçekleştirilen montaj eyleminin doğru bir sırada gerçekleştirilip gerçekleştirilmediğinin belirlenmesi, gerekiyorsa çalışana doğru montaj eylemi hakkında bilgi verilmesi,
- Sağ el ve sol eldeki nesnelerin (montaj bileşenleri ve araçlarının) tespit edilmesi için montaj eylemi sınıfı bilgisinin girdi olarak sağlanması,
- Çalışanın hata oranının değerlendirilmesi için yanlış sırada gerçekleştirilen montaj eylemleri bilgilerinin girdi olarak sağlanması.

‘Kapasite ve Performansın İzlenmesi ve Kontrolü’ bileşeninde montaj eylemlerinin tanınması modeli sayesinde 5 temel işlev gerçekleştirilebilecektir:

- Çalışanların gerçek zamanlı performanslarının belirlenmesi,
- Üretilebilecek ürün miktarının tahmin edilmesi,
- Ürünlerin müşteriye teslim sürelerinin tahmin edilmesi,
- Çalışanın gerçek zamanlı performansının, öğrenme ve kendini geliştirme oranı performansının değerlendirilmesi,
- Çalışanların işlem süreleri bazında yorgunluk ve dikkatsizlik durumlarının belirlenmesi.

‘Depolama/Envanterin İzlenmesi ve Kontrolü’ bileşeninde montaj eylemlerinin tanınması modeli sayesinde 1 temel işlev gerçekleştirilebilecektir:

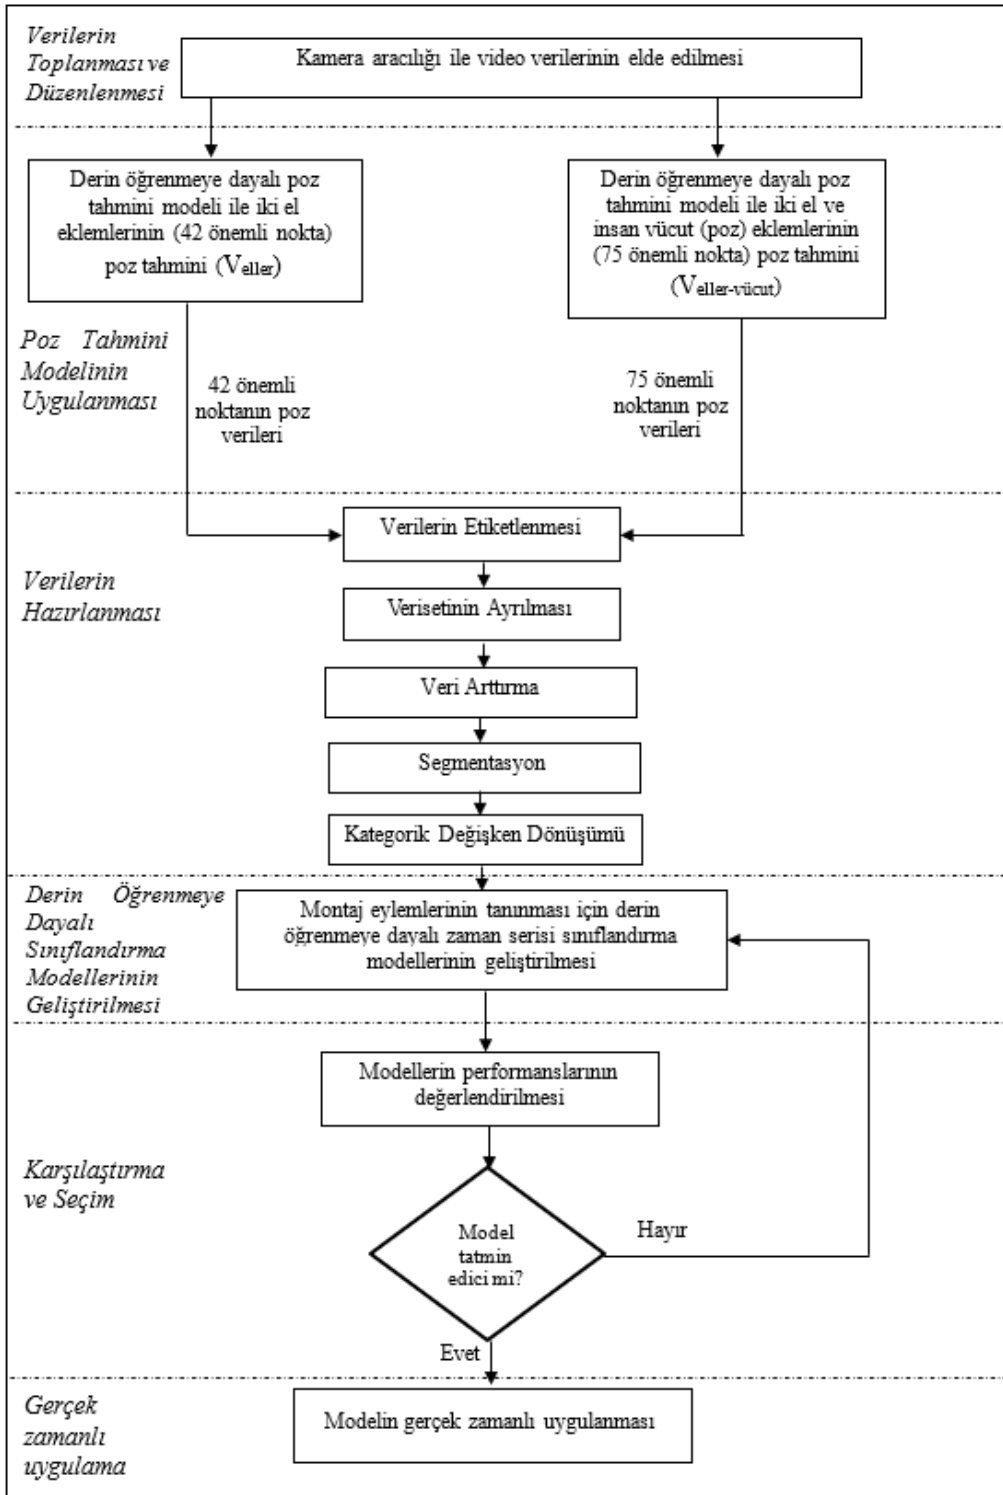
- Yatailerdeki montaj bileşenlerinin yeterli olabileceği sürenin belirlenmesi.

‘Ergonomi ve Güvenliğin İzlenmesi ve Kontrolü’ bileşeninde montaj eylemlerinin tanınması modeli sayesinde 4 temel işlev gerçekleştirilebilecektir:

- Montaj işlemlerinin ergonomik uygunluklarının belirlenmesi,
- Çalışana uygun montaj eylemlerinin belirlenmesi,

- Çok fazla güç gerektiren zorlu görevlerin belirlenmesi,
- Üretim performansını arttırabilecek duruşların belirlenmesi.

Bu bölümde, montaj eylemlerinin tanınması modelinin geliştirilmesi için önerilen metodolojinin detayları verilmektedir. Şekil 4.2’de sunulan çalışma metodolojisi verilerin toplanması ve düzenlenmesi, poz tahmini modelinin uygulanması, verilerin hazırlanması, derin öğrenmeye dayalı sınıflandırma modellerinin geliştirilmesi, karşılaştırma ve seçim ve gerçek zamanlı uygulama olmak üzere 6 temel aşamadan oluşmaktadır. Çalışmada kullanılacak olan eğitim ve test veri setinin elde edilmesi amacıyla, çalışan hareketlerini içeren video verileri toplanır. Daha sonra video bölümlerinden elde edilen resimlere poz tahmini modeli uygulanarak 3B poz verileri elde edilir. Verilerin derin öğrenme modellerine uygun bir formatta olmasını sağlamak için verilerin etiketlenmesi, veri setinin ayrılması, veri arttırma, segmentasyon ve kategorik değişken dönüşümü olmak üzere beş adımlı veri hazırlama süreci uygulanır. Derin öğrenmeye dayalı sınıflandırma modellerinin geliştirilmesi aşamasında, elde edilen nitelikler ve sınıf etiketleri kullanılarak, çeşitli derin öğrenme algoritmalarına dayalı sınıflandırma modelleri eğitilir. Eğitilen bu modeller, test veri setindeki girdi verilerinden bir sınıf etiketi tahmini için ayrı ayrı kullanılır. Bu şekilde modellerin performansları değerlendirilir. En iyi performansı veren model gerçek zamanlı uygulama aşamasında kullanılır.



Şekil 4.2. Montaj Eylemleri Tanınması Modelinin Çalışma Metodolojisi.

4.1. Verilerin Toplanması ve Düzenlenmesi

Veri toplama, sınıflandırma sürecinde izlenen ilk adım olarak bilinmektedir (Alawneh ve ark, 2021). Bu aşama, çalışmada kullanılacak olan çalışan hareketi veri setinin geliştirilmesi için video görüntülerinin kamera aracılığı ile elde edilmesi ve

düzenlenmesi aşamasıdır. Çalışan hareket verilerini taşıyan video görüntülerinin toplanması ve kaydedilmesinin ardından elde edilen video, her bir ürünün her bir montaj eylemi için ayrılacaktır. Daha sonra montaj eylemlerinin her bir videosunun çerçeve sayıları çıkarılarak analiz edilecektir. Bu aşama sonucunda poz tahmini için kullanılacak olan video görüntüleri elde edilecektir.

A bir ürünün gerçekleştirilmesi için gerekli toplam montaj eylemi sayısı olmak üzere, $ME = (ME_1, ME_2, \dots, ME_A)$ a ile indekslenen, verilen sırada gerçekleştirilen ve çalışmada tahmin edilmek istenilen montaj eylemlerini gösterebilir. Modelin geliştirilmesi için çalışan/çalışanlardan eğitim ve test veri seti oluşturmak amacıyla, B sayıda ürün için ($b=1,2,\dots,B$) tüm montaj eylemlerinin görüntülerini içeren $h=30$ fps (saniye başına düşen kare sayısı) hızında, $H \times W$ resim çözünürlüğünde kaydedilen toplam J çerçeve sayısına sahip G videosu elde edilir. Burada $G_j, j=0,1,2,\dots,J-1$ olmak üzere j. zaman adımında (time step) kamera aracılığı ile elde edilen video çerçevesidir. Elde edilen G videosu her bir ürünün her bir montaj eylemi için farklı çerçeve sayılarına sahip olabilen toplam $A*B$ adet $G_{b,a}$ videosuna ayrılır. $l_{b,a} \in ME$ olduğunda, $G_{b,a}$ videosunun etiketidir. $C_{b,a}$ b. ürünün a. montaj eylemine ait videonun çerçeve sayısı olmak üzere, her bir $G_{b,a}$ videosunun çerçeve sayıları elde edilir ve analiz edilir. Burada $J = \sum_{b=1}^B \sum_{a=1}^A C_{b,a}$ olmaktadır. Verilerin toplanması ve düzenlenmesi aşaması için önerilen algoritma Tablo 4.1’de verilmektedir.

Tablo 4.1. Verilerin toplanması ve düzenlenmesi aşaması algoritması adımları.

Algoritma 1. Verilerin Toplanması ve Düzenlenmesi Aşaması

Girdi: A – montaj eylemi sayısı,

B – ürün sayısı

G_j – Girdi videosunun j . çerçevesi

h – saniye başına düşen kare sayısı

Çıktı: H – görüntü çözünürlüğünün yükseklik boyutu

W – görüntü çözünürlüğünün genişlik boyutu

$G_{b,a}$ – b . ürünün a . montaj eylemi videosu

$C_{b,a}$ – b . ürünün a . montaj eylemi videosunun çerçeve sayısı

$l_{b,a}$ – $G_{b,a}$ videosunun etiketi (montaj sınıfı)

```
1:  $G \leftarrow \{\}$ 
2: for  $j=0$  to  $J-1$  do
3:    $G_j \leftarrow \text{GORUNTUAL}(h,H,W)$  //Her bir zaman adımında görüntülerin okunması
4:    $G \leftarrow G \cup G_j$ 
5: end for
6:  $\text{KAYDET}(G)$  //Elde edilen videonun kaydedilmesi
7: for  $b=1$  to  $B$  do
8:   for  $a=1$  to  $A$  do
9:      $G_{b,a} \leftarrow \text{AYIR}(G)$  //Toplam videonun her bir ürünün her bir montaj eylemi için
video bölümlerine ayrılması
10:     $l_{b,a} \leftarrow \text{ME}_a$  //Video bölümlerinin etiketlerinin belirlenmesi
11:     $C_{b,a} \leftarrow \text{CERCEVEHESAPLA}(G_{b,a})$  //Video bölümlerinin çerçeve sayılarının
belirlenmesi
12:    return  $G_{b,a}, C_{b,a}, l_{b,a}$ 
13:   end for
14: end for
```

4.2. Poz Tahmini

Bu aşamada, montaj eylemlerinin sınıflandırılması uygulamalarında kullanılacak olan veri setinin girdi değerlerinin elde edilmesi için poz tahmini modeli uygulanacaktır. İnsan davranışı hakkında faydalı bilgiler sağlayan pozlar, insan aktivitelerinin tanınmasında kayda değer bir başarı elde etmiştir. Dolayısıyla, araştırmacılar tarafından son zamanlarda popülerlik kazanan görüntü-tabanlı insan aktivite tanıma sistemlerinde yaygın olarak kullanılmaktadır (Gupta ve ark, 2021). Poz tahmini,

görüntülerde veya videolarda insan eklemlerinin veya önceden tanımlanmış kilit noktaların 2B veya 3B konumlarının bulunmasını ve iskelet konumu gibi bir vücut temsili oluşturmayı amaçlayan bilgisayarlı görme problemidir (Sheppard ve ark, 2021; Sujatha ve ark, 2022; Zheng ve ark, 2021). Bu kilit noktalar, burun, gözler, ağız, dirsekler, dizler gibi insan vücudunun ana noktalarıdır (Bahukhandi ve Gupta, 2021; Dileep ve ark, 2022). 2B’da her bir eklemin (x, y) koordinatları tahmin edilirken, 3B’da (x, y, z) koordinatları tahmin edilir (Sujatha ve ark, 2022). İnsan pozu için poz tahmin tekniklerini geliştirmek amacıyla birçok çalışma yapılmıştır. Tahmin oluşturmaya yönelik geleneksel yaklaşımlar, karmaşık konfigürasyonlar ve vücut parçasının tıkanması gibi karmaşık faktörler konusunda sınırlı yeteneklere sahipti (Sheppard ve ark, 2021). Bu nedenle derin öğrenmeye dayalı yaklaşımlar geliştirilmiştir. Derin öğrenmeyi insan poz tahminine uygulayan ilk büyük çalışma 2014 yılında yayınlanan DeepPose'dur (Toshev ve Szegedy, 2014). Bu çalışmada, poz tahmini vücut eklemlerine yönelik derin sinir ağı tabanlı bir regresyon problemi olarak formüle edilmiştir ve vücut eklemlerinin sadece 2B koordinat bilgileri sağlanmaktadır. Poz tahmini için geliştirilen derin öğrenmeye dayalı bir diğer yaklaşım olan OpenPose (Cao ve ark, 2017) insan vücudu, el, yüz ve ayak anahtar/kilit noktalarını (toplamda 135 anahtar nokta) görüntüler üzerinde 2B olarak ortaklaşa algılayan ilk çok kişili açık kaynaklı bir sistemdir. Poz çıkarma için Evrişimsel Poz Makineleri (CPM) adı verilen çok aşamalı bir mimari kullanır (Iyer ve ark, 2021).

Bu tez çalışmasında, video görüntülerinden çalışan poz verilerinin elde edilmesi yani çalışan iskelet noktalarının konumlarının çıkartılması amacıyla Google tarafından geliştirilmiş açık kaynaklı MediaPipe Holistic (Grishchenko ve Bazarevsky, 2020) altyapısı kullanılmaktadır. MediaPipe Holistic’in, poz (MediaPipe Pose), yüz (MediaPipe Face Mesh) ve el (MediaPipe Hands) olmak üzere gerçek zamanlı çalışabilen üç bileşeni bulunmaktadır. Bu bileşenler sayesinde sırasıyla 33 poz anahtar noktası, 468 yüz anahtar noktası ve el başına (sağ ve sol el) 21 el anahtar noktası olmak üzere toplam 543 anahtar nokta çıkartılabilmektedir. Poz tahmini altyapılarından biri olan OpenPose’dan farklı olarak MediaPipe Holistic’te, pozlar sınıflandırma yerine regresyon kullanılarak 2B yerine 3B olarak tahmin edilir (Moryossef ve ark, 2021). Bu çalışmada MediaPipe Holistic bünyesindeki Medipipe Pose ve MediaPipe Hands bileşenlerinden yararlanılmıştır. Blaze Pose modelini (Bazarevsky ve ark, 2020) kullanan MediaPipe Pose, RGB görüntülerinden 3B koordinat (x, y ve z) değerleri ve

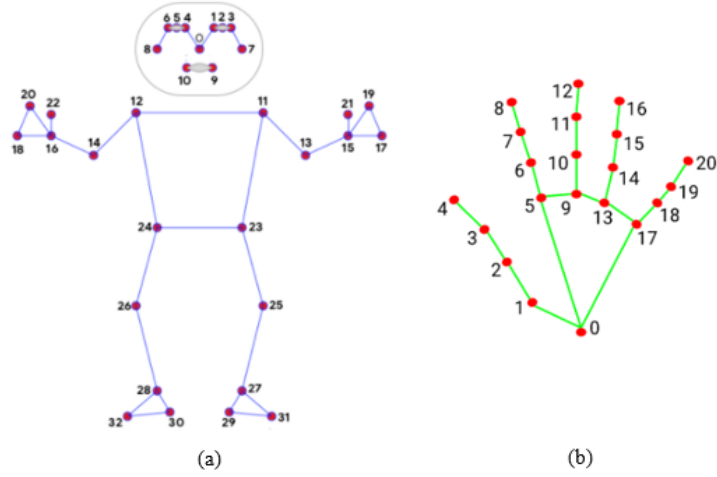
anahtar noktanın görüntüde görünür olma olasılığını ifade eden görünürlük değerleri (v) ile Şekil 4.3 (a)'da gösterilen 33 anahtar noktayı tahmin eder. x ve y koordinatları için görüntü genişliği ve yüksekliğine göre [0.0-1.0] arasında normalize edilmiş değerlerini verir. Derinlik bilgisini gösteren ve anahtar noktanın kameradan uzaklığına dair bir tahmin sağlayan z koordinatı bilek konumunu orijin olarak kullanır. e_p vücuttaki kilit noktası indeksini göstermek üzere ($e_p=0,1,2,\dots,32$), MediaPipe Pose modelinin uygulanmasıyla j. çerçevede elde edilen poz verileri (P_j^p) şu şekilde ifade edilebilmektedir:

$$P_j^p = [x_{0,j}^p, y_{0,j}^p, z_{0,j}^p, v_{0,j}^p, \dots, x_{e_p,j}^p, y_{e_p,j}^p, z_{e_p,j}^p, v_{e_p,j}^p, \dots, x_{32,j}^p, y_{32,j}^p, z_{32,j}^p, v_{32,j}^p] \quad (4.1)$$

MediaPipe Hands (Zhang ve ark, 2020b), RGB görüntülerine öncelikle BlazePalm adında bir avuç içi algılama modeli ve ardından el anahtar noktası konumunu belirleme modeli uygulayarak her bir el için Şekil 4.3 (b)'de gösterilen 21 anahtar noktayı ve bu noktaların 3B koordinatlarını (x, y ve z) tahmin eder. e_{rh} sağ eldeki kilit noktası indeksini ($e_{rh}=0,1,2,\dots,20$), e_{lh} sol eldeki kilit noktası indeksini ($e_{lh}=0,1,2,\dots,20$) göstermek üzere, MediaPipe Hands modelinin uygulanmasıyla j. çerçevede elde edilen sağ el poz verileri (P_j^{rh}) Denklem 4.2'deki gibi, sol el poz verileri ise (P_j^{lh}) Denklem 4.3'teki gibi ifade edilebilmektedir.

$$P_j^{rh} = [x_{0,j}^{rh}, y_{0,j}^{rh}, z_{0,j}^{rh}, v_{0,j}^{rh}, \dots, x_{e_{rh},j}^{rh}, y_{e_{rh},j}^{rh}, z_{e_{rh},j}^{rh}, v_{e_{rh},j}^{rh}, \dots, x_{20,j}^{rh}, y_{20,j}^{rh}, z_{20,j}^{rh}, v_{20,j}^{rh}] \quad (4.2)$$

$$P_j^{lh} = [x_{0,j}^{lh}, y_{0,j}^{lh}, z_{0,j}^{lh}, v_{0,j}^{lh}, \dots, x_{e_{lh},j}^{lh}, y_{e_{lh},j}^{lh}, z_{e_{lh},j}^{lh}, v_{e_{lh},j}^{lh}, \dots, x_{20,j}^{lh}, y_{20,j}^{lh}, z_{20,j}^{lh}, v_{20,j}^{lh}] \quad (4.3)$$



Şekil 4.3. MediaPipe Holistic altyapısı ile elde edilebilen kilit noktalar (a) MediaPipe Pose (MediaPipe Github, 2020) (b) MediaPipe Hands (MediaPipe Github, 2019).

MediaPipe Pose ve MediaPipe Hands modelleri tarafından elde edilebilen kilit noktalarının isimleri sırasıyla Tablo 4.2 ve Tablo 4.3'te verilmektedir.

Tablo 4.2. MediaPipe Pose modeli tarafından elde edilen kilit noktalarının isimleri.

İndeks	Kilit Nokta İsmi	İndeks	Kilit Nokta İsmi
0	burun (nose)	17	sol serçe parmağı (left_pinky)
1	sol göz içi (left_eye_inner)	18	sağ serçe parmağı (right_pinky)
2	sol göz (left_eye)	19	sol işaret parmağı (left_index)
3	sol göz dışı (left_eye_outer)	20	sağ işaret parmağı (right_index)
4	sağ göz içi (right_eye_inner)	21	sol baş parmak (left_thumb)
5	sağ göz (right_eye)	22	sağ baş parmak (right_thumb)
6	sağ göz dışı (right_eye_outer)	23	sol kalça (left_hip)
7	sol kulak (left_ear)	24	sağ kalça (right_hip)
8	sağ kulak (right_ear)	25	sol diz (left_knee)
9	ağzın sol köşesi (mouth_left)	26	sağ diz (right_knee)
10	ağzın sağ köşesi (mouth_right)	27	sol ayak bileği (left_ankle)
11	sol omuz (left_shoulder)	28	sağ ayak bileği (right_ankle)
12	sağ omuz (right_shoulder)	29	sol topuk (left_heel)
13	sol dirsek (left_elbow)	30	sağ topuk (right_heel)
14	sağ dirsek (right_elbow)	31	sol ayak baş parmağı (left_foot_index)
15	sol bilek (left_wrist)	32	sağ ayak baş parmağı (right_foot_index)
16	sağ bilek (right_wrist)		

Tablo 4.3. MediaPipe Hands modeli tarafından elde edilen kilit noktaların isimleri.

İndeks	Kilit Nokta İsmi	İndeks	Kilit Nokta İsmi
0	bilek (wrist)	11	orta parmak DIP (middle_finger_DIP)
1	başparmak (thumb_CMC)	CMC	12 orta parmak TIP (middle_finger_TIP)
2	başparmak MCP (thumb_MCP)	13	yüzük parmağı MCP (ring_finger_MCP)
3	başparmak IP (thumb_IP)	14	yüzük parmağı PIP (ring_finger_PIP)
4	başparmak TIP (thumb_TIP)	15	yüzük parmağı DIP (ring_finger_DIP)
5	işaret parmağı MCP (index_finger_MCP)	16	yüzük parmağı TIP (ring_finger_TIP)
6	işaret parmağı PIP (index_finger_PIP)	17	serçe parmağı MCP (pinky_MCP)
7	işaret parmağı DIP (index_finger_DIP)	18	serçe parmağı PIP (pinky_PIP)
8	işaret parmağı TIP (index_finger_TIP)	19	serçe parmağı DIP (pinky_DIP)
9	orta parmak MCP (middle_finger_MCP)	20	serçe parmağı TIP (pinky_TIP)
10	orta parmak PIP (middle_finger_PIP)		

Çalışmada montaj eylemlerinin tanınması modelinin geliştirilmesinde iki yaklaşım karşılaştırılmaktadır: MediaPipe Holistic (hands) ve MediaPipe Holistic (handsUpose). V_t elde edilmek istenilen veri seti olsun. $t \in K_{poz} = \{\text{eller, eller-vücut}\}$ olduğunda, sadece MediaPipe holistic (hands) kullanılarak elde edilen veri seti V_{eller} olarak belirtilmiştir. MediaPipe holistic (hands) ve MediaPipe holistic (pose) kullanılarak elde edilen veri seti ise $V_{eller-vücut}$ olarak ifade edilmiştir. Poz tahmini ile oluşturulan veri setlerinin özellikleri Tablo 4.4'teki gibidir. V_{eller} 'de her bir zaman adımı yani her bir çerçeve için toplam 126 girdi değişkeni bulunurken, $V_{eller-vücut}$ 'da toplam 258 girdi değişkeni bulunmaktadır.

Tablo 4.4. Elde edilen veri setlerinin özellikleri.

Veri Seti	Yaklaşım	Girdi Niteliği Sayısı (I_t)	Girdi Niteliği Değerleri
V_{eller}	MediaPipe holistic (hands)	126	<ul style="list-style-type: none"> Sağ ve sol el anahtar noktaları için 3B (x, y ve z) koordinatlarının [0-1] aralığında normalize edilmiş değerleri
$V_{eller-vücut}$	MediaPipe Holistic (HandsUPose)	258	<ul style="list-style-type: none"> Poz anahtar noktaları için 3B (x, y ve z) koordinatlarının ve görünürlük değerlerinin (v) [0-1] aralığında normalize edilmiş değerleri Sağ ve sol el anahtar noktaları için 3B (x, y ve z) koordinatlarının [0-1] aralığında normalize edilmiş değerleri

Veri seti oluşturma aşamasında, b ürününün a montaj işlemini içeren videoya poz tahmini uygulanarak her bir zaman adımı için kilit noktaları değerlerini içeren $V_t^{b,a}$ örnekleri elde edilir. Bu işlem sırasında, her bir $G_{b,a}$ videosunun sırasıyla tüm m. zaman adımıdaki ($m=0,1,2,\dots, C_{b,a}-1$) $G_{b,a,m}$ çerçeveleri için poz tahmini modeli çalıştırılır ve videonun her bir çerçevesinde $D_{i,m}^{t,b,a}$ değerlerinden oluşan I_t boyutunda d_m vektörleri elde edilir. Bu d_m vektörü sadece ellerdeki kilit noktalar için m. zaman adımıdaki $P_m^{lh}UP_m^{rh}$ değerlerini içerirken, eller ve vücuttaki kilit noktalarının birleşimi için $P_m^pUP_m^{lh}UP_m^{rh}$ değerlerine karşılık gelmektedir. $i=1,2,\dots,I_t$ olmak üzere, poz tahmini ile elde edilen girdi niteliğini ifade etsin. Bu şekilde her bir $G_{b,a}$ videosu için $V_t^{b,a}$ örnekleri elde edilir. Tablo 4.4'te görüldüğü gibi, I_t elde edilmek istenilen veri setinin toplam nitelik sayısı değeri olduğu varsayıldığında, $V_{eller}^{b,a}$ örnekleri için I_{eller} değeri 126 iken, $V_{eller-vücut}^{b,a}$ örnekleri için $I_{eller-vücut}$ değeri 258'dir. m. zaman adımıdaki $d_m^{t,b,a}$ vektörü Denklem 4.4'teki gibi ifade edilmektedir.

$$d_m^{t,b,a} = [D_{1,m}^{t,b,a}, D_{2,m}^{t,b,a}, D_{3,m}^{t,b,a}, \dots, D_{I_t,m}^{t,b,a}], \quad \forall m, m = 0,1,2, \dots, C_{b,a} - 1 \quad (4.4)$$

$V_t^{b,a}$ örneğinin etiketi $E_t^{b,a}$, videonun etiketi olan $I_{b,a}$ değerini alır. İşlemler sonucu elde edilen $V_t^{b,a}$ örneğinin ve $E_t^{b,a}$ etiketinin şekli ve içeriği Şekil 4.4'teki gibidir.

$$\begin{bmatrix}
D_{1,0}^{t,b,a} & D_{2,0}^{t,b,a} & D_{3,0}^{t,b,a} & D_{4,0}^{t,b,a} & \dots & D_{I_t,0}^{t,b,a} \\
D_{1,1}^{t,b,a} & D_{2,1}^{t,b,a} & D_{3,1}^{t,b,a} & D_{4,1}^{t,b,a} & \dots & D_{I_t,1}^{t,b,a} \\
D_{1,2}^{t,b,a} & D_{2,2}^{t,b,a} & D_{3,2}^{t,b,a} & D_{4,2}^{t,b,a} & \dots & D_{I_t,2}^{t,b,a} \\
D_{1,3}^{t,b,a} & D_{2,3}^{t,b,a} & D_{3,3}^{t,b,a} & D_{4,3}^{t,b,a} & \dots & D_{I_t,3}^{t,b,a} \\
D_{1,4}^{t,b,a} & D_{2,4}^{t,b,a} & D_{3,4}^{t,b,a} & D_{4,4}^{t,b,a} & \dots & D_{I_t,4}^{t,b,a} \\
D_{1,5}^{t,b,a} & D_{2,5}^{t,b,a} & D_{3,5}^{t,b,a} & D_{4,5}^{t,b,a} & \dots & D_{I_t,5}^{t,b,a} \\
\dots & \dots & \dots & \dots & \dots & \dots \\
D_{1,C_{b,a}-1}^{t,b,a} & D_{2,C_{b,a}-1}^{t,b,a} & D_{3,C_{b,a}-1}^{t,b,a} & D_{4,C_{b,a}-1}^{t,b,a} & \dots & D_{I_t,C_{b,a}-1}^{t,b,a}
\end{bmatrix}
\begin{matrix}
\left[l_{b,a} \right] \leftarrow E_t^{b,a} \text{ etiketi} \\
\uparrow \\
V_t^{b,a} \text{ örneği}
\end{matrix}$$

Şekil 4.4. $V_t^{b,a}$ örneğinin ve $E_t^{b,a}$ etiketinin temsili görüntüsü.

Poz tahmininin uygulanması aşaması için önerilen algoritma Tablo 4.5'te verilmektedir. Bu aşamadan sonraki aşamalar V_{eller} ve $V_{eller-vücut}$ veri seti için ayrı ayrı uygulanacaktır.

Tablo 4.5. Poz tahmininin uygulanması aşaması algoritması adımları.

Algoritma 2. Poz Tahmininin Uygulanması Aşaması

Girdi: $G_{b,a}$ – b. ürünün a. montaj eylemi videosu

$C_{b,a}$ – b. ürünün a. montaj eylemi videosunun çerçeve sayısı

$l_{b,a}$ – $G_{b,a}$ videosunun etiketi

Çıktı: $V_t^{b,a}$ – b. ürünün a. montaj eylemi için d_m poz dizilerini içeren örnek

$E_t^{b,a}$ – $V_t^{b,a}$ örneğinin etiketi

```

1: for b=1 to B do
2:   for a=1 to A do
3:      $V_t^{b,a} \leftarrow \{ \}$ 
4:     for m=0 to  $C_{b,a}-1$ 
5:        $d_m^{t,b,a} \leftarrow \{ \}$ 
6:        $d_m^{t,b,a} \leftarrow \text{POZTAHMİNİ}(G_{b,a,m})$ 
7:        $V_t^{b,a} \leftarrow V_t^{b,a} \cup d_m^{t,b,a}$ 
8:     end for
9:      $E_t^{b,a} \leftarrow l_{b,a}$ 
10:   end for
11: return  $V_t^{b,a}, E_t^{b,a}$ 
12: end for

```

4.3. Verilerin Hazırlanması

Veri setlerinin derin öğrenmeye dayalı sınıflandırma modellerine uygun bir yapıda girdi verisi olarak sağlanabilmesi için elde edilen poz verilerine belirli veri ön işleme işlemleri uygulanması gerekmektedir. Bu çalışmada, verilerin hazırlanması aşaması sırası ile verilerin etiketlenmesi, veri setinin ayrılması, veri artırma, segmentasyon ve kategorik değişken dönüşümü olmak üzere 5 temel adımdan oluşmaktadır.

4.3.1. Verilerin etiketlenmesi

İnsan aktivite tanıma modelleri makine öğrenmesinde denetimli öğrenme konusu içerisinde zaman serisi verilerinin girdi olduğu ve aktivite sınıfının çıktı olduğu çok değişkenli bir zaman serisi sınıflandırma problemidir (Dua ve ark, 2021; Mekruksavanich ve Jitpattanakul, 2022; Verma ve ark, 2022). Bu nedenle veri setinin denetimli öğrenme problemine uygun yapıda oluşturulması gerekir. Denetimli öğrenme, öğrenmek istenilen verilerdeki her satır için doğru beklenen çıktıyı içeren açık bir etiket gerektirir (Pajankar ve Joshi, 2022). Bu çalışmada girdiler (bağımsız değişkenler) her bir çerçevede elde edilen poz verileri, çıktı (bağımlı değişken) ise tahmin edilmek istenilen montaj eylemidir. Bu aşamada üzerinde çalışılan veri setinin denetimli öğrenmeye uygun bir yapıya dönüştürülmesi için girdi verilerine etiket değerleri eklenerek çıktı değişkenini de içeren veri seti oluşturulacaktır.

$V_t^{b,a}$ poz tahmini aşamasında oluşturulan b ürününün a montaj eylemi videosunun $d_m^{t,b,a}$ poz verisi dizilerini taşıyan örnek ($a=1,2,..,A$ ve $b=1,2,..,B$), $C_{b,a}$ ise $G_{b,a}$ videosunun çerçeve sayısı olmak üzere, her bir $V_t^{b,a}$ örneklerinin sırasıyla tüm m. zaman adımındaki ($m=0,1,2,.., C_{b,a}-1$) $d_m^{t,b,a}$ vektörleri alınır ve her bir satırda $D_{i,j}^t$ değerlerinden oluşan I_t boyutunda d_j^t vektörleri elde edilir. j. zaman adımındaki d_j^t vektörü Denklem 4.5'teki gibi ifade edilmektedir.

$$d_j^t = [D_{1,j}^t, D_{2,j}^t, D_{3,j}^t, \dots, D_{I_t,j}^t], \quad \forall j, j = 0,1,2, \dots, J - 1 \quad (4.5)$$

Burada $j=0,1,2,..,J-1$ ve $J = \sum_{b=1}^B \sum_{a=1}^A C_{b,a}$ 'dir. $i=1,2,..,I_t$ olmak üzere, poz tahmini ile elde edilen girdi niteliğini ifade eder. d_j^t vektörüne ait etiket niteliği değeri E_j , $E_t^{b,a}$ değerini alır. d_j^t vektörüne E_j etiket niteliği değerinin eklenmesiyle k_j^t vektörleri elde edilir. j. zaman adımındaki k_j^t vektörü Denklem 4.6'daki gibi ifade edilmektedir:

$$k_j^t = [D_{1,j}^t, D_{2,j}^t, D_{3,j}^t, \dots, D_{I_t,j}^t, E_j], \quad \forall j, j = 0, 1, 2, \dots, J-1 \quad (4.6)$$

Daha sonra tüm k_j^t vektörleri birleştirilerek $J * (I_t+1)$ boyutlu V_t veri seti oluşturulur.

İşlemler sonucu elde edilen V_t veri setinin şekli ve içeriği Şekil 4.5'teki gibidir.

$$\begin{bmatrix} D_{1,0}^t & D_{2,0}^t & D_{3,0}^t & D_{4,0}^t & \dots & D_{I_t,0}^t & E_0 \\ D_{1,1}^t & D_{2,1}^t & D_{3,1}^t & D_{4,1}^t & \dots & D_{I_t,1}^t & E_1 \\ D_{1,2}^t & D_{2,2}^t & D_{3,2}^t & D_{4,2}^t & \dots & D_{I_t,2}^t & E_2 \\ D_{1,3}^t & D_{2,3}^t & D_{3,3}^t & D_{4,3}^t & \dots & D_{I_t,3}^t & E_3 \\ D_{1,4}^t & D_{2,4}^t & D_{3,4}^t & D_{4,4}^t & \dots & D_{I_t,4}^t & E_4 \\ D_{1,5}^t & D_{2,5}^t & D_{3,5}^t & D_{4,5}^t & \dots & D_{I_t,5}^t & E_5 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ D_{1,J-1}^t & D_{2,J-1}^t & D_{3,J-1}^t & D_{4,J-1}^t & \dots & D_{I_t,J-1}^t & E_{J-1} \end{bmatrix}$$

Şekil 4.5. V_t veri setinin temsili görüntüsü

Verilerin etiketlenmesi aşaması için önerilen algoritma Tablo 4.6'da verilmektedir.

Tablo 4.6. Verilerin etiketlenmesi aşaması algoritması adımları.

Algoritma 3. Verilerin etiketlenmesi aşaması

Girdi $V_t^{b,a}$ – b. ürünün a. montaj eylemi için d_m poz dizilerini içeren örnek

$C_{b,a}$ – b. ürünün a. montaj eylemi videosunun çerçeve sayısı

$E_t^{b,a}$ – $V_t^{b,a}$ örneğinin etiketi

Çıktı V_t – Poz nitelikleri ve etiket niteliğini içeren veri seti

```

1:  $V_t \leftarrow \{\}$ 
2:  $j=0$ 
3: for  $b=1$  to  $B$  do
4:   for  $a=1$  to  $A$  do
5:     for  $m=0$  to  $C_{b,a}-1$ 
6:        $d_j^t \leftarrow d_m^{t,b,a} // d_m^{t,b,a} \in V_t^{b,a}$ 
7:        $E_j \leftarrow E_t^{b,a}$ 
8:        $k_j^t \leftarrow d_j^t \cup E_j$ 
9:        $V_t \leftarrow V_t \cup k_j^t$ 
10:       $j+=1$ 
11:    end for
12:  end for
13: end for
14: return  $V_t$ 

```

4.3.2. Veri setinin ayrılması

Bu aşama veri setinin eğitim ve test veri seti olarak ayrılması aşamasıdır. Makine öğrenmesinde eğitim-test veri seti ayrılması verilerin örneklere göre ikiye bölünmesidir. Burada, modeli oluşturmak için makine öğrenmesi algoritmasına verilmek üzere verilerin yalnızca bir kısmı kullanılır. Model eğitilirken bazı maliyet veya amaç fonksiyonlarının optimize edilmesi amacıyla modelin parametrelerinin veya ağırlıklarının iteratif bir şekilde ayarlanması için kullanılan bu kısım eğitim veri seti olarak adlandırılır. Test veri seti ise modelin oluşturulması aşamasında kullanılmayan ve modelin performansının ölçüldüğü kısımdır (Banejee ve ark, 2023; Kerner ve ark, 2022; Korstanje, 2022).

Bu aşamada V_t veri seti belirlenen bir oranda video verilerini taşıyan V_t^E eğitim veri seti ve V_t^T test veri seti olmak üzere ikiye ayrılır. V_t^E veri seti toplam J^E zaman adımından oluşurken, V_t^T test veri setinde J^T adet zaman adımı verileri bulunmaktadır.

4.3.3. Veri arttırma

İnsan aktivite tanıma çalışmalarında belirli bir frekansta örneklenen sensör veya kamera, aktivite verilerini toplar. Örnekleme işleminde örnekleme frekansı, örneklemenin başlangıç zaman noktası ve örnekleme süresi gibi faktörler olabilmektedir (Wang ve ark, 2022c). Gerçek zamanlı insan aktivite tanıma uygulamalarında özellikle veri örnekleme oranı/frekansı hem sınıflandırma doğruluğu hem de hesaplama yükü (Computational Load) ve kamera veya sensörün enerji ihtiyacı açısından modellerin performansını etkileyen önemli faktörler arasında yer almaktadır (Bersch ve ark, 2014; Eerdekens ve ark, 2020). Bilindiği gibi, test denekleriyle deneyleri tekrar tekrar çalıştırmak her zaman mümkün olmamaktadır (Bersch ve ark, 2014). Bu nedenle, montaj eylemlerinin tanınması modeli için önerilen metodolojinin ilk aşamasında yer alan ve sadece sınırlı deneklerin aktivitelerinin belirli bir hız ve ölçekte kaydedildiği veri toplama, aktivite sınıflandırma çalışmalarındaki en kritik adımlardan birisi olma özelliğine sahiptir. Veri toplama aşamasında karar verilmesi gereken örnekleme oranı seçimi ile ilgili yetersiz örnekleme ve aşırı örnekleme olmak üzere iki olumsuz durum ortaya çıkabilmektedir (Bersch ve ark, 2014; Zhang ve ark, 2020c). Düşük örnekleme hızı oturma ve kalkma gibi basit faaliyetlerin tanınmasında yeterli olabilir fakat montaj eylemleri gibi daha ince tanecikli kombinatoriyal aktiviteleri tespit etmek söz konusu olduğunda tatmin edici performans elde edilemeyebilir (Chung ve ark, 2019). Örnekleme oranı olması gerektiğinden düşük

seçildiğinde meydana gelebilen yetersiz örnekleme durumunda bilgi kaybı oluşabilir (Bersch ve ark, 2014). Bu şekilde eğitilen model her bir faaliyetin birbirinden farklı olabilen içsel niteliklerini yakalamakta başarısız olabilir (Chung ve ark, 2019). Örnekleme oranının yüksek seçilmesi veri analizi için yeterli bilgi sağlayabilir fakat olması gerektiğinden yüksek seçildiğinde ortaya çıkan aşırı örnekleme durumunda ise elde edilen bilgiler istenmeyen gürültü ile sonuçlanabilir. Aynı zamanda, daha fazla verinin işlenmesini gerektireceğinden analiz için hesaplama süresinin daha uzun olmasına neden olabilir. Bunun yanısıra, büyük veri boyutu ve hesaplama yükü ile sisteme yük getirir (Bersch ve ark, 2014; Chung ve ark, 2019).

Veri seyrekliği ve sonucunda oluşabilecek aşırı öğrenme sorunlarının üstesinden gelmenin ve model üzerindeki etkilerini azaltmanın yollarından biri veri arttırmadır (Alawneh ve ark, 2021; Han ve ark, 2021; Hoelzemann ve ark, 2021; Iwana ve Uchida, 2021a; Iwana ve Uchida, 2021b; Nunez ve ark, 2018; Oh ve ark, 2020; Wang ve ark, 2022c; Zhang ve ark, 2020c). Veri arttırma, modelin performansını iyileştirmek amacıyla, modeli eğitmek için kullanılacak eğitim veri setinin boyutunu arttırmak için keşfedilmemiş girdi alanını kapsayan sentetik veri örnekleri oluşturmak ve bu yeni verileri ek eğitim girdileri olarak kullanmaktır (Alawneh ve ark, 2021; Huang ve Lin, 2018; Iwana ve Uchida, 2021a; Oh ve ark, 2020; Ramachandra ve ark, 2021; Wen ve ark, 2020). Veri arttırmanın genellemeyi iyileştirdiği ve aşırı öğrenme sorununu çözmeye etkili bir yaklaşım olduğu bilinmektedir (Oh ve ark, 2020; Ramachandra ve ark, 2021). Görüntü verileri üzerinde veri arttırma yöntemlerinin geliştirilmesi alanında çok çalışma olsa da zamansal bağımlılığa sahip zaman serileri için veri arttırma yöntemlerinin sayısı oldukça sınırlıdır (Iwana ve Uchida, 2021a; Iwana ve Uchida, 2021b; Le Guennec ve ark, 2016; Wen ve ark, 2020).

Bu çalışmada aşağıdaki amaçları gerçekleştirmek için eğitim veri seti için aşağı örnekleme ve ölçekleme (scaling) işlemlerini içeren iki adımlı bir veri arttırma yaklaşımı önerilmektedir:

- Yüksek örneklemeden kaynaklanabilecek yüksek hesaplama yükü ve düşük hız, düşük örneklemeden kaynaklanabilecek veri kaybının önlenmesi,
- Az miktarda yetersiz eğitim veri setinden kaynaklanabilecek derin öğrenme modellerinin aşırı öğrenme sorunlarının üstesinden gelinmesi,

- Modellerin montaj eylemlerinin tanınması üzerine performansının iyileştirilmesi.

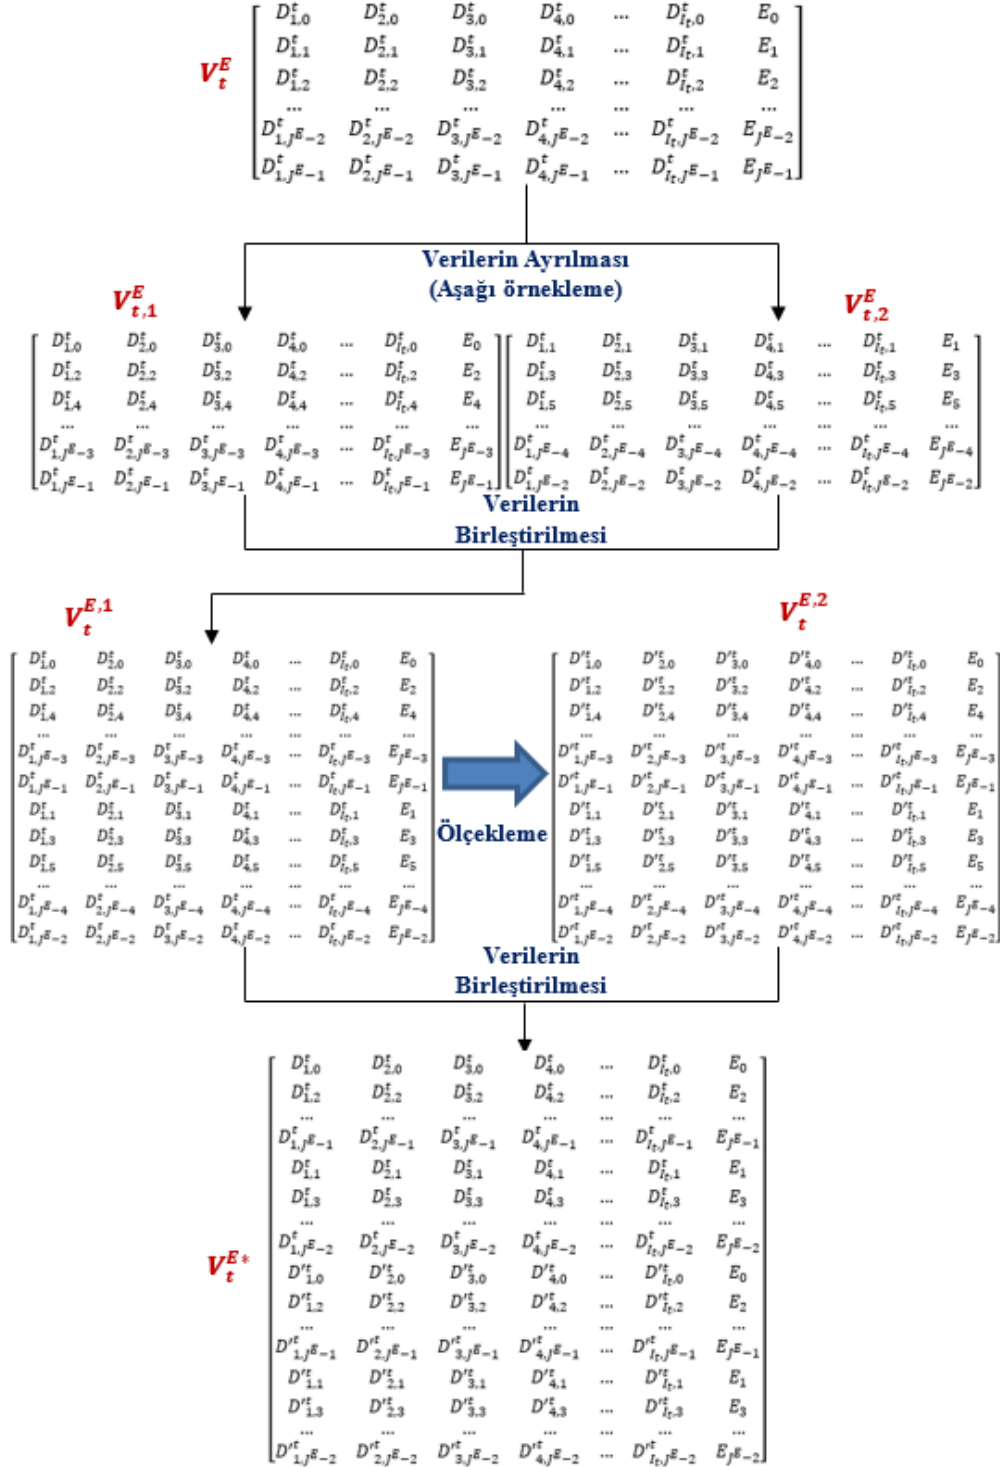
Aşağı örnekleme, değerleri rastgele veya düzenli örnekleme ile filtreleme işlemidir (Wang ve ark, 2021). Bu çalışmada düzenli aşağı örnekleme uygulanmıştır. Ölçekleme, zaman serisindeki tüm elemanların büyüklüğünün rastgele bir ölçekleyici (skaler) ile çarpılarak değiştirilmesidir. Bu rastgele ölçekleyici, ortalaması 1, standart sapması hiperparametre olarak belirlenen bir σ olan bir Gauss dağılımı ile belirlenebilir (Iwana ve Uchida, 2021a; Iwana ve Uchida, 2021b; Oh ve ark, 2020).

Veri arttırma aşamasına kadar oluşturulan V_t^E veri seti ve V_t^T veri seti, veri toplama aşamasında 30 fps hızında kaydedilen videolardan elde edilmiştir. Ancak modelin gerçek zamanlı daha hızlı uygulanabilmesi ve hesaplama yükünün azaltılması için model çevrim içi uygulamada 15 fps hızında çalışacaktır. Bir taraftan çevrimiçi tahmin aşamasında 15 fps hızında alınacak olan poz verilerinin derin öğrenme modelleri tarafından uygun bir performans ile tahmin edilmesini sağlamak, diğer taraftan yetersiz eğitim veri setinden kaynaklı aşırı öğrenmeyi önlemek için 30 fps hızındaki videolardaki verileri içeren V_t^E eğitim veri setine bu çalışmada önerilen veri arttırma yaklaşımı uygulanarak V_t^{E*} veri seti elde edilir.

Önerilen veri arttırma aşamasının ilk adımında eğitim V_t^E veri seti aşağı-örnekleme uygulanarak iki bölüme ayrılır. Yani 30 fps örnekleme oranı bulunan veri seti 15 fps örnekleme oranındaki iki farklı veri setine dönüştürülür. Ayrılmadan sonra elde edilen ilk veri seti $V_{t,1}^E$, V_t^E veri setindeki ilk örnekten başlayan ve birer örnek aralıklı k_j veri dizilerini kapsayacak şekilde oluşturulan veri setidir. İkinci veri seti $V_{t,2}^E$ ise ikinci örnekten başlayan ve birer örnek aralıklı $k_j^{E,t}$ veri dizilerini kapsayacak şekilde oluşturulan veri setidir. Daha sonra, aşağı-örneklemenin uygulanmasından kaynaklanabilecek veri kaybını önlemek için $V_{t,1}^E$ ve $V_{t,2}^E$ veri seti birleştirilerek tek bir $V_t^{E,1}$ veri seti oluşturulur.

İkinci adımda, elde edilen bu zaman serisi veri setinin ($V_t^{E,1}$) poz değerlerine ölçekleme veri arttırma yaklaşımı uygulanır ve yeni bir veri seti ($V_t^{E,2}$) elde edilir. $V_t^{E,2}$ veri setinin etiket değerleri, $V_t^{E,1}$ veri setinin etiket değerlerini alır. Daha sonra iki adımda oluşturulan $V_t^{E,1}$ ve $V_t^{E,2}$ veri setleri birleştirilerek V_t^{E*} ile ifade edilen yeni bir eğitim veri seti oluşturulur. Bu işlem, $t \in K_{\text{poz}} = \{\text{eller, eller-vücut}\}$ olmak üzere, $J^E * (I_t + 1)$

boyutlu V_{eller}^E , $V_{\text{eller-vücut}}^E$ veri setlerinin her ikisi için de ayrı ayrı uygulanarak, $2J^E * (I_t+1)$ boyutunda V_{eller}^{E*} ve $V_{\text{eller-vücut}}^{E*}$ veri setleri elde edilir. V_t^E veri seti için iki aşamalı veri arttırma işlemi Şekil 4.6' da gösterilmektedir.



Şekil 4.6. V_t^E veri seti için veri arttırma işlemi.

Test veri setine (V_t^T) veri arttırma işlemi uygulanmamıştır. Gerçek zamanlı uygulamada model 15 fps örnekleme oranı ile çalışacağından, önceki aşamalarda 30 fps örnekleme oranı ile elde edilmiş test veri setine aşağı örnekleme uygulanarak V_t^T veri seti eğitim veri setinde olduğu gibi $V_{t,1}^T$ ve $V_{t,2}^T$ olmak üzere iki bölüme ayrılmıştır. Bir sonraki aşamada kullanılacak olan V_t^{T*} veri seti $V_{t,1}^T$ veri setine eşitlenmiştir. Veri arttırma aşaması için önerilen algoritma Tablo 4.7’de verilmektedir.

Tablo 4.7. Veri arttırma aşaması algoritması adımları.

Algoritma 4. Veri Arttırma Aşaması

Girdi V_t^E – Poz nitelikleri ve etiket niteliğini içeren eğitim veri seti

V_t^T – Poz nitelikleri ve etiket niteliğini içeren test veri seti

σ – Ölçekleyici dağılımının standart sapması

Çıktı V_t^{E*} – Veri arttırma işlemi sonrası poz nitelikleri ve etiket niteliğini içeren eğitim veri seti

V_t^{T*} – Aşağı örnekleme işlemi sonrası poz nitelikleri ve etiket niteliğini içeren test veri seti

1: $V_{t,1}^E \leftarrow \{\}$

2: $V_{t,2}^E \leftarrow \{\}$

3: $V_t^{E,1} \leftarrow \{\}$

4: $V_t^{E,2} \leftarrow \{\}$

5: $V_t^{E*} \leftarrow \{\}$

6: $V_{t,1}^T \leftarrow \{\}$

7: $V_t^{T*} \leftarrow \{\}$

//Eğitim veri setinin oluşturulması (Aşağı örnekleme U Ölçekleme)

8: for j=0 to J^E-1 ; j += 2 do

9: $V_{t,1}^E \leftarrow V_{t,1}^E \cup k_j^{E,t} // k_j^{E,t} \in V_t^E$

10: end for

11: for j=1 to J^E-1 ; j += 2 do

12: $V_{t,2}^E \leftarrow V_{t,2}^E \cup k_j^{E,t} // k_j^{E,t} \in V_t^E$

13: end for

14: $V_t^{E,1} \leftarrow V_{t,1}^E \cup V_{t,2}^E$

15: $V_t^{E,2} \leftarrow \text{Ölçekleme}(V_t^{E,1}, \sigma)$

16: $V_t^{E*} \leftarrow V_t^{E,1} \cup V_t^{E,2}$

//Test veri setinin oluşturulması (Aşağı örnekleme)

17: for j=0 to J^T-1 ; j += 2 do

18: $V_{t,1}^T \leftarrow V_{t,1}^T \cup k_j^{T,t} // k_j^{T,t} \in V_t^T$

19: end for

20: $V_t^{T*} \leftarrow V_{t,1}^T$

21: return V_t^{E*}, V_t^{T*}

4.3.4. Segmentasyon

Aktivite tanıma sürecindeki en önemli adımlardan biri olan veri segmentasyonu, zaman serisi verilerini daha küçük parçalara ayırarak verilerin segmentlerini oluşturmaktır (Csizmadia ve ark, 2022; Gao ve ark, 2021). Bu segmentleri oluşturmak için genellikle üç farklı pencereleme tekniği kullanılır: olay-tanımlı pencere tekniği (event-defined window technique), aktivite-tanımlı pencere tekniği (activity-defined window technique) ve kayan pencere tekniği (sliding window). Olay tanımlı pencere tekniği, art arda veri bölümlenmeyi tanımlamak için kullanılan belirli olayları bulmak için ön işlemenin gerekli olduğu tekniktir. Aktivite-tanımlı pencere tekniğinde veri segmentasyonu etkinlik değişikliklerinin saptanmasına dayanmaktadır. Kayan pencere tekniğinde ise veriler sabit uzunlukta bir kayan pencere kullanılarak sabit boyutlu dizilere (segmentlere) bölünür (Attal ve ark, 2015; Csizmadia ve ark, 2022; Ma ve ark, 2019, Odhiambo ve ark, 2022).

Aktivite verilerinin uzunluğu kişiler arasında ve aktiviteler arasında farklılıklar gösterebilmektedir. Değişken boyuttaki bu aktivite verileri, genellikle girdi olarak sabit boyutlu verileri kullanan sinir ağlarında doğrudan girdi olarak kullanılamamaktadır (Han ve ark, 2021). Diğer taraftan, kayan pencere yaklaşımı, uygulanması basit olduğu ve herhangi bir ön işleme gerektirmediğinden gerçek zamanlı uygulamalara oldukça uygundur (Attal ve ark, 2015; Banos ve ark, 2014; Csizmadia ve ark, 2022; Odhiambo ve ark, 2022). Aynı zamanda periyodik aktiviteleri sınıflandırmada oldukça verimlidir (Hirawat ve ark, 2022). Aktivite tanıma çalışmalarında segmentasyon aşamasında kayan pencere tekniği en yaygın kullanılan yaklaşımdır (Atalaa ve ark, 2020; Günther ve ark, 2019; Dehghani ve ark, 2019a; Kozina ve ark, 2011; Ma ve ark, 2019).

Bu nedenlerden dolayı bu çalışmada, derin öğrenme ağlarını eğitmeden önce eğitim ve test örnekleri elde etmek için veri segmentasyonu kayan pencere tekniği kullanılarak gerçekleştirilecektir. Kayan pencere tekniğinde her bir zaman adımında elde edilen veriler sabit uzunluktaki ve süredeki pencerelere bölünür. WS pencere büyüklüğü, i nitelik sayısı ($i=1,2,3,\dots,I_t$ ve $I_{eller}=126$, $I_{eller-vücut}=258$) olmak üzere, V_t^{E*} eğitim veri setindeki poz niteliği verileri sabit uzunluklu kayan pencere tekniği ile $V_t^{GE}=[O_1^{t,E}, O_2^{t,E}, \dots, O_f^{t,E}, \dots, O_{F_1}^{t,E}]$ olacak şekilde her bir $O_f^{t,E}$ örneğine yani WS zaman adımına ve her bir zaman adımı ile ilişkili I_t niteliklerine sahip örneklere (segmentlere) dönüştürülür. Burada, girdi vektörünün uzunluğu (diğer bir ifadeyle örnek büyüklüğü)

WS, kanal (nitelik) sayısı ise I_t olmaktadır ve bir örnek bir aktiviteyi temsil etmektedir. $d_w^{E,t,f}$, $O_f^{t,E}$ eğitim örneğinin içerdiği zaman adımlarındaki vektörleri gösterebilir. Bu durumda $O_f^{t,E} = [d_0^{E,t,f}, d_1^{E,t,f}, d_2^{E,t,f}, \dots, d_w^{E,t,f}, \dots, d_{WS-1}^{E,t,f}]$ olmaktadır. $O_f^{t,E}$ örneği içerisinde bulunan her bir w zaman adımındaki $D_{i,w}^{E,t,f}$ poz niteliği değerlerini taşıyan $d_w^{E,t,f}$ vektörü Denklem 4.7'deki gibi ifade edilmektedir.

$$d_w^{E,t,f} = [D_{1,w}^{E,t,f}, D_{2,w}^{E,t,f}, D_{3,w}^{E,t,f}, \dots, D_{I_t,w}^{E,t,f}], \quad \forall w, w = 0, 1, 2, \dots, WS - 1 \quad (4.7)$$

Kayan pencere tekniği iki şekilde uygulanabilmektedir: örtüşen pencereler ve örtüşmeyen pencereler (Dehghani ve ark, 2019b). Örtüşmeyen kayan pencereler yönteminde, ardışık zaman pencereleri arasında ortak veri örnekleri paylaşılmamaktadır (Kozina ve ark, 2011). Ardışık pencereler arasında örtüşme olduğu durumlarda ise kayan pencere tekniği örtüşen kayan pencere (overlapping sliding window) tekniği adını almaktadır (Dehghani ve ark, 2019a). Her bir aralıktaki veriler diğer aralık verilerine bağımlı olduğunda, aralıkların ayrı ayrı işlenmesi durumunda, oluşturulan komşu pencereler/segmentler örtüşmüyor ise pencereler sınırında eksik bilgiler olabilmektedir (Ahad ve ark, 2020). Bu nedenle, örtüşmeyen pencereler veri setindeki etkinlik geçişi içerisindeki önemli olayları kaçırabilir (Dehghani ve ark, 2019b). Bu çalışmada, montaj etkinlikleri arasındaki geçişlerde eylem tanınabilirliğinin sağlanabilmesi amacıyla örtüşen kayan pencere tekniği kullanılmıştır.

Veri arttırma aşamasında elde edilen V_t^{E*} eğitim veri seti $2J^E * I_t$ boyutunda bir matris biçimindedir. Segmentasyon aşamasında iki ardışık segment arasında belirli bir örtüşme oranı (overlapping ratio- 'OVR') verildiğinde, burada kayma adımı s Denklem 4.8'deki gibi hesaplanmaktadır.

$$s = WS * (\%100 - \%OVR) \quad (4.8)$$

Kayma adımı s , segmentler oluşturulurken bir sonraki segmentin başlayacağı konumu bulmada kullanılır. $j=0,1,2,\dots, 2J^E-1$ olmak üzere birinci segment j_0 konumundaki $d_{j_0}^{E,t}$ vektörü ile başlıyor ise ikinci segment $j_0 + s$ konumundaki $d_{j_0+s}^{E,t}$ vektörü ile başlamaktadır (Yin ve ark, 2022). Burada, örtüşme oranı $\%OVR=\%0$ verilirse kayma adımı s pencere büyüklüğü WS değerine eşit olmaktadır. İşlemler sonucunda F_1 sayıda

örneğe sahip $F_1 * WS * I_t$ boyutunda V_t^{GE} eğitim girdi veri seti elde edilir. Bu veri setindeki toplam segment sayısı F_1 , Wang ve ark. (2018b)'nin sunmuş olduğu denklemden yararlanılarak Denklem 4.9'daki şekilde hesaplanabilir.

$$F_1 = \frac{2J^E - (WS - s)}{s} \quad (4.9)$$

Bu aşamadaki diğer bir adım her pencereye belirli bir aktivite etiketinin atanmasıdır (Gao ve ark, 2021; Kozina ve ark, 2011). Bu şekilde her bir segmente karşılık gelen etiket değerlerini/eylem sınıflarını (ED_f) barındıran V_t^{CE} eğitim çıktı veri seti elde edilir. Bazı çalışmalarda (Kozina ve ark, 2011; Mahmud ve ark, 2020) segment içerisinde en sık karşılaşılan aktivite o segmente karşılık gelen etiket değeri olarak atanmıştır. Diğer taraftan bazı çalışmalarda (Csizmadia ve ark, 2022; Hoelzemann ve ark, 2021; Ordóñez ve Roggen, 2016), pencereye atanan etiket pencerenin son örneği ile aynı olacak şekilde belirlenmiştir. Bu çalışmada $O_f^{t,E}$ eğitim segmentine ait etiket değeri olan ED_f^E , $O_f^{t,E}$ örneğinin WS. satırındaki, diğer bir deyişle segmentin son örneği $d_{WS-1}^{E,t,f}$ vektörüne karşılık gelen E_{WS-1}^f değeridir. Bu şekilde $F_1 * 1$ boyutunda V_t^{CE} vektörü elde edilir. Benzer şekilde, V_t^{T*} test veri setine segmentasyon işlemi uygulanarak F_2 sayıda $O_f^{t,T}$ örneklerine sahip $F_2 * WS * I_t$ boyutunda V_t^{GT} test girdi veri seti ve ED_f^T etiket değerlerine sahip V_t^{CT} elde edilir.

Veriler segmentlere ayrıldıktan sonra CNN, LSTM ve GRU gibi bazı derin öğrenme algoritmaları, eşit uzunlukta sıralı girdiler aldığı için girdi örneklerinin uzunluklarını eşit hale getirmek amacıyla tüm girişler doldurulmalıdır (Dwarampudi ve Reddy, 2019). Kayıp verilere sahip zaman serileri dolgu (padding) işlemi ile doldurulur (Yin ve ark, 2022). p dolgu değeri olmak üzere, bu çalışmada eksik zaman adımlarının doldurulması amacıyla kullanılan t uzunluğundaki dolgu vektörü PV , $PV \in R^t$ olmak üzere $PV = [p, p, p, \dots, p]$ şeklinde ifade edilebilir. Segmentasyon işlemi sonrası elde edilen her bir örnek bir tanıma algoritması ile tek bir aktiviteye sınıflandırılır (Attal ve ark, 2015; Csizmadia ve ark, 2022; Ma ve ark, 2019). Eğitim veri setine yönelik segmentasyon aşaması için önerilen algoritma Tablo 4.8'de verilmektedir.

Tablo 4.8. Eğitim veri seti için segmentasyon aşaması algoritması adımları.

Algoritma 4. Eğitim Veri Seti için Segmentasyon Aşaması

Girdi V_t^{E*} – Veri arttırma işlemi sonrası poz nitelikleri ve etiket niteliğini içeren eğitim veri seti

WS – Pencere büyüklüğü

α – Örtüşme oranı

p – dolgu değeri

Çıktı V_t^{GE} – Segmentasyon işlemi sonrası eğitim girdi veri seti

V_t^{CE} – Segmentasyon işlemi sonrası eğitim çıktı veri seti

```
1:  $V_t^{GE} \leftarrow \{\}$ 
2:  $V_t^{CE} \leftarrow \{\}$ 
3:  $s = WS * (\%100 - \alpha)$ 
4:  $f = 1$ 
5: for  $j = 0$  to  $2J^E - WS$ ;  $j += s$  do
6:    $O_f^{t,E} \leftarrow \{\}$ 
7:   for  $k = j$  to  $j + WS$  do
8:      $O_f^{t,E} \leftarrow O_f^{t,E} \cup d_k^{E,t}$ 
9:   end for
10:   $O_f^{t,E} \leftarrow \text{DOLDUR}(O_f^{t,E}, WS, p)$ 
11:   $V_t^{GE} \leftarrow V_t^{GE} \cup O_f^{t,E}$ 
12:   $ED_f^E \leftarrow E_k^E$ 
13:   $V_t^{CE} \leftarrow V_t^{CE} \cup ED_f^E$ 
14:   $f += 1$ 
15: end for
16: return  $V_t^{GE}, V_t^{CE}$ 
```

Segmentasyon sürecinde pencere büyüklüğü ve örtüşme oranı sınıflandırma modelinin performansını önemli ölçüde etkileyebilir. Bu nedenle dikkatli bir şekilde seçilmelidir. Uzun bir pencere birden fazla aktivite içerebilir ve sınıflandırmanın doğruluğunu azaltırken, kısa pencere tek bir etkinliği iki bitişik pencereye bölebilir ve aktivite tanıma için yetersiz olabilir (Atalaa ve ark, 2020; Chen ve ark, 2021; Hirawat ve ark, 2022; Li ve ark, 2019). Örtüşme oranı ile ilişkili kayma adımı boyutu ise ne kadar küçükse, veri serisi o kadar gerçek zamanlıdır. Daha küçük adım boyutu performansı artırır, ancak pencere sayısını artırır ve algılamayı yavaşlatabilir (Odhiambo ve ark, 2022).

4.3.5. Kategorik değişken dönüşümü

Sinir ağlarının eğitiminde verilerin modele girdi olarak verilmeden önce kategorik verilere sahip niteliklerin kodlanması ve sayısal verilere dönüştürülmesi gerekmektedir (Singh ve Chauhan, 2022). Bu işlem genellikle tamsayı kodlama/etiket kodlama (integer encoding/ label encoding) veya tek sıcak kodlama (one-hot encoding) yöntemleri kullanılarak yapılır (Owen, 2022). Her kategori için benzersiz bir tamsayının atandığı tamsayı kodlama, değişkenler arasında sıralı bir ilişki varsa kullanılabilir (Ahad ve ark, 2020). Bu çalışmada, kategorik değişken dönüşümü için sıralı ilişkinin olmadığı kategorik değişkenler için kullanılacak olan tek sıcak kodlama yaklaşımı uygulanmaktadır. Tek sıcak kodlama sınıf etiketlerini ikili değerlere (0 ve 1) sahip bir vektör olarak temsil etme sürecini ifade eder. Örneğin, etiket değişkeninin “sarı”, “kırmızı”, “mavi”, “yeşil”, “beyaz” değerlerinden birini alabildiği 5 sınıfa sahip olduğu varsayalım. Burada “yeşil” sınıf etiketi değeri için one-hot kodlanmış vektör $[0, 0, 0, 1, 0]$ olmaktadır (Ganegedara, 2022). Tek-sıcak kodlama ile, bir kategorik özneliğin tüm değerlerinin birbirinden eşit uzaklıkta olduğu belirtilir (Yu ve ark, 2022).

Bir önceki aşamada elde edilen V_t^{CE} ve V_t^{CT} çıktı veri setleri, etiketleri yani hedef değişkenini gösterirken, V_t^{GE} ve V_t^{GT} sırasıyla eğitim ve test girdi veri setinde bulunan nitelikler, hedefi belirleyen bağımsız değişkenleri ifade etmektedir. $V_t^{CE} = [ED_1^E, ED_2^E, \dots, ED_f^E, \dots, ED_{F_1}^E]$ ve F_1 eğitim veri setindeki toplam örnek sayısı olmak üzere V_t^{CE} $F_1 * 1$ boyutunda bir vektördür. Burada $ME = (ME_1, ME_2, \dots, ME_a, \dots, ME_A)$ çalışmada tahmin edilmek istenilen montaj eylemleri olmak üzere tüm $ED_f^E \in ME$ 'dir. Etiket niteliğine tek sıcak kodlama işleminin uygulanması ile birlikte, V_t^{CE} vektöründeki her bir ED_f^E değeri 0-1 ikili tamsayı değerli vektöre dönüşürken, $F_1 * A$ boyutunda V_t^{CE*} tensörü elde edilir. Tensör, makine öğrenmesi uygulamalarında veri setinin tutulduğu çok boyutlu bir veri dizisidir (Maruthi ve ark., 2024). Burada $V_t^{CE*} = [EDS_1^E, EDS_2^E, \dots, EDS_f^E, \dots, EDS_{F_1}^E]$ dir ve EDS_f^E , eğitim girdi veri setindeki f. örneğin etiket değerinin $EDD_{a,f}^E$ değerlerinden oluşan A boyutunda ikili değerli vektörüdür. Yani, $EDD_{a,f}^E \in [0,1]$ 'dir. Eğitim veri setindeki f örneğinin EDS_f^E vektörü Denklem 4.10'daki gibi ifade edilmektedir.

$$EDS_f^E = [EDD_{1,f}^E, EDD_{2,f}^E, EDD_{3,f}^E, \dots, EDD_{A,f}^E], \quad \forall f, j = 1, 2, \dots, F_1 \quad (4.10)$$

Benzer şekilde V_t^{CT} çıktı veri setine kategorik değişken dönüşümü uygulanarak EDS_f^T ikili değerli vektörlerden oluşan $F_1 * A$ boyutunda V_t^{CT*} tensörü elde edilir. Eğitim çıktı veri setine yönelik kategorik değişken dönüşümü aşaması için algoritma Tablo 4.9'da verilmektedir.

Tablo 4.9. Kategorik değişken dönüşümü aşaması algoritması adımları.

Algoritma 5. Kategorik Değişken Dönüşümü Aşaması

Girdi V_t^{CE} – Eğitim çıktı veri seti

ME_a – Montaj eylemi

Çıktı V_t^{CE*} – Segmentasyon işlemi sonrası eğitim çıktı veri seti

```

1:  $V_t^{CE*} \leftarrow \{ \}$ 
2: for  $f=1$  to  $F_1$  do
3:    $EDS_f^E \leftarrow \{ \}$ 
4:   for  $a=1$  to  $A$  do
5:     if  $ED_f^E = ME_a$  then
6:        $EDD_{a,f}^E = 1$ 
7:     else
8:        $EDD_{a,f}^E = 0$ 
9:      $EDS_f^E \leftarrow EDS_f \cup EDD_{a,f}^E$ 
11:  end for
12:  $V_t^{CE*} \leftarrow V_t^{CE*} \cup EDS_f^E$ 
13: end for
14: return  $V_t^{CE*}$ 

```

Algoritmanın uygulanması sonucu elde edilen veri setlerinin boyutları Tablo 4.10'daki gibi olmaktadır.

Tablo 4.10. Eğitim ve test veri setlerinin boyutu.

Veri seti	Veri seti bölümü	Boyutu
V_t	Eğitim girdi veri seti (V_t^{GE})	$((F_1), WS, I_t)$
	Test girdi veri seti (V_t^{GT})	$((F_2), WS, I_t)$
	Eğitim çıktı veri seti (V_t^{CE})	$((F_1), A)$
	Test çıktı veri seti (V_t^{CT})	$((F_2), A)$

4.4. Derin Öğrenmeye Dayalı Sınıflandırma Modellerinin Geliştirilmesi

Bu çalışmada montaj eylemlerinin tanınması amacıyla, nihai çıktısı bir ürünün montajının baştan sona tamamlanması için gerekli A adet montaj eyleminin sınıflandırma sonuçları olan CNN, LSTM, GRU, BiLSTM ve BiGRU olmak üzere 5 derin öğrenme modeli ve bu modellerin birleştirilmesi ile oluşturulan derin öğrenme tabanlı hibrit modeller kullanılmıştır. Hibrit modeller CNN ağının diğer dört ağ mimarisi (LSTM, GRU, BiLSTM ve BiGRU) ile kombinasyonu şeklinde yapılandırılmıştır. Bu hibrit modeller arasında CNN-LTSM, CNN-GRU, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN bulunmaktadır. Geliştirilen derin öğrenme tabanlı modellerin uzunlukları önceden tanımlanmış bir değerdir (Zhao ve ark, 2019). Bu çalışmada bu değer segmentasyon aşamasında belirlenen pencere uzunluğudur. Giriş zaman serisi verileri eksik/boş değerler içeriyorsa, eğitim sürecinde boş değerler hesaplanmadığından derin öğrenme tabanlı modeller başarısız olacaktır (Cui ve ark, 2018; Zou ve ark, 2019). Bu çalışmada gerçek zamanlı uygulamada ilk pencere dolana kadar gecikme olmadan modelin tahmin yapabilmesini sağlamak için girdi verilerine veri hazırlama aşamasında dolgu işlemi uygulanmıştır. Fakat eksik değerler sıfır veya önceden tanımlanmış diğer bazı değerler olarak ayarlanırsa, eğitim ve test sonuçları oldukça önyargılı olacaktır (Cui ve ark, 2018; Zou ve ark, 2019). Bu nedenle bu çalışmada derin öğrenmeye dayalı sınıflandırıcı modeller tasarlanırken her bir modele ilk olarak maskeleyme (Masking) katmanı eklenmiştir. Maskeleyme katmanı, zaman adımındaki giriş tensörünün değerlerinin tümü belirlenen bir değere eşitse, o zaman adımı için eksik verileri temsil eden tüm aşağı akış katmanları için zaman adımını maskeler yani atlar (Liu ve ark, 2018b). Geliştirilen derin öğrenme modellerinin bağımlı değişkeni montaj eylemi sınıfı iken bağımsız değişkenleri aşağıdaki şekildedir:

- V_{eller} veri seti için 126 nitelik: El anahtar noktaları (42 nokta) için ise x, y ve z koordinatları değerleri.
- $V_{eller-vücut}$ veri seti için 258 nitelik: Poz anahtar noktaları (33 nokta) için x, y ve z koordinatları ve görünürlük değerleri ve el anahtar noktaları (42 nokta) için ise x, y ve z koordinatları değerleri.

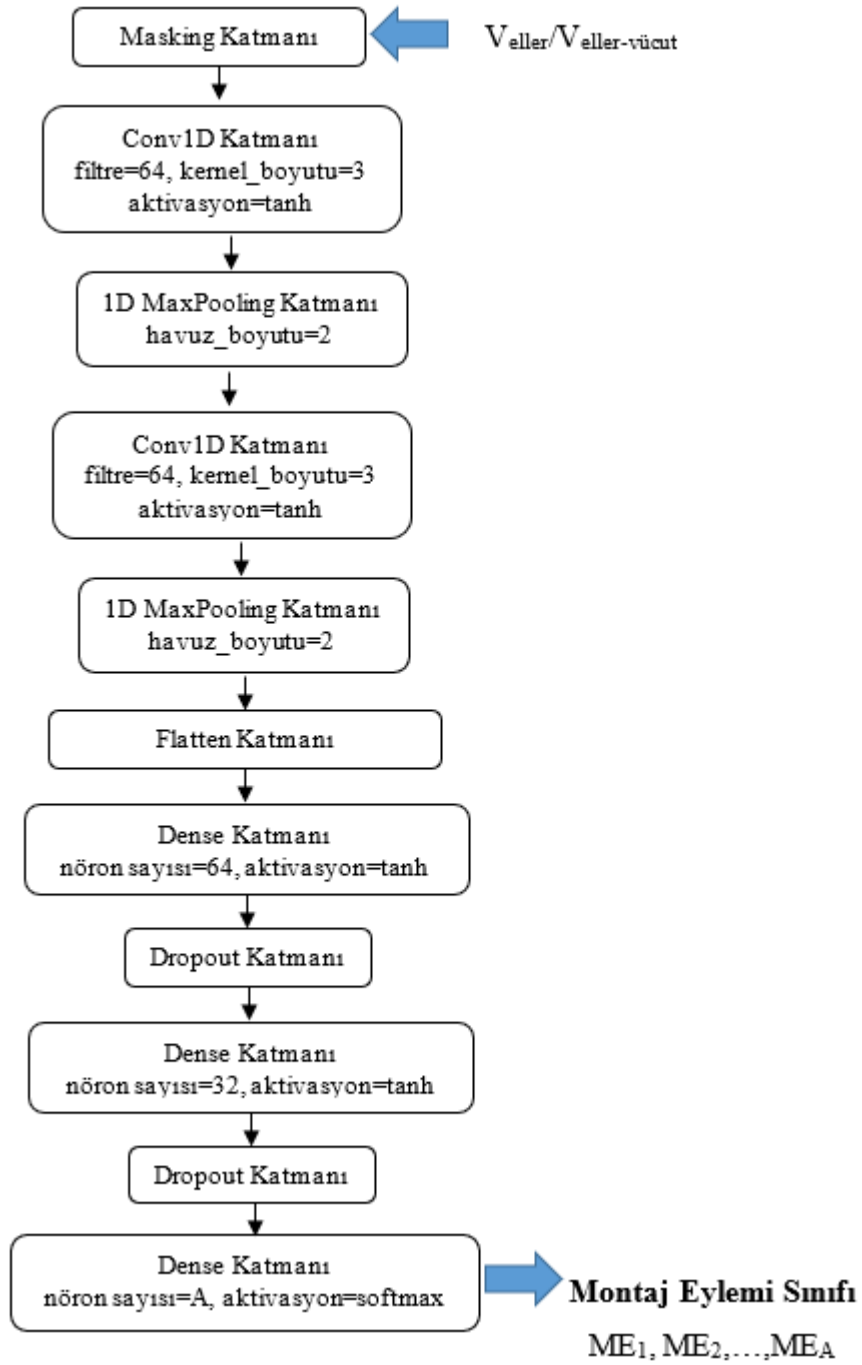
Geliştirilen montaj eylemlerinin tanınması modeli sınıflandırma görevini gerçekleştirecektir. Zeki Serü Üretim Sistemi bileşenleri elde edilen bu bilgi sayesinde

yanlış gerçekleştirilen montaj eylemlerinin tespit edilmesi, montaj eylem sürelerinin, montaj eylem sıklıklarının belirlenmesi gibi her bir bileşen içerisinde kendi görevlerini yerine getirebilecektir. Bu bölümde montaj eylemlerinin tanınması modeli için geliştirilen on adet derin öğrenme modelinin mimarisi anlatılmaktadır.

4.4.1. CNN modeli

Çalışmada tasarlanan CNN modelinin ağ yapısı Şekil 4.7’de gösterilmektedir. Model 11 katmandan oluşmaktadır. Segmentlere ayrılmış ham poz verileri ilk olarak maskeleme (Masking) katmanına girdi olarak verilir. Maskeleme katmanı $WS \times I_t$ ’lik bir giriş ve çıkış şekline sahiptir. Burada, WS örnek sayısını yani pencere uzunluğunu, I_t (V_{eller} veri seti için $I_t = 126$, $V_{eller-vücut}$ veri seti için $I_t = 258$) ise poz niteliği sayısını ifade etmektedir. Her hareket dizisi örneği, poz tahmini ile çalışan kilit noktalarından çıkarılan her özelliği temsil eden bir giriş vektöründen oluşmaktadır (Millar ve ark, 2020). Maskeleme katmanından sonra 64 filtreli, evrişim penceresinin uzunluğu yani çekirdek (kernel) boyutu 3 olan 1-boyutlu evrişim (Conv1D) katmanı bulunmaktadır. Bu katman belirtilen uzunluk (WS) ve genişlikteki (I_t) çok değişkenli zaman serilerini okur (Luwe ve ark, 2022) ve tanh (hiperbolik tanjant) aktivasyon fonksiyonu kullanmaktadır. Evrişim penceresinin adım sayısı (stride) 1’dir. Evrişim katmanı tarafından oluşturulan özellik haritaları havuz boyutu (pool size) 2 olan 1-boyutlu bir maksimum havuzlama (1D MaxPooling) katmanına beslenir. Maksimum havuzlama katmanı, parametre bilgilerini azaltmak için özellik dizisinin maksimum değerini çıkarır ve verileri aşağı örnekleme biçiminde sıkıştırır (Xu ve ark, 2019b). Havuzlama katmanı aşırı öğrenmeyi önler (Xu ve ark, 2019b), boyutsallığın azaltılmasına ve küçük bozulmalara ve kaymalara karşı değişmezlik oluşturulmasına yardımcı olur (Dua ve ark, 2021). Maksimum havuzlama katmanından sonra tekrar sırasıyla, tanh aktivasyon fonksiyonuna sahip, 64 filtreli, çekirdek boyutu 3, adım sayısı 1 olan ikinci bir 1-boyutlu evrişim (Conv1D) katmanı ve havuz boyutu 2 olan 1-boyutlu bir maksimum havuzlama (1D MaxPooling) katmanı daha ilave edilmiştir. Evrişim katmanı ve havuzlama katmanı kombinasyonunun iki kez kullanılmasının nedeni, bir kez kullanıldığında modelin yetersiz öğrenmeye (underfitting) eğilimli olmasından kaynaklanmaktadır (Angerbauer ve ark, 2021). Bu katmandan elde edilen çıktı bir düzleştirme (Flatten) katmanı ile düzleştirilir. Ardından ikisi de tanh aktivasyon fonksiyonu kullanan bir 64 nöronlu tam bağlantılı (Dense) katman ile bir 32 nöronlu tam bağlantılı katmana gönderilir. Kayıp fonksiyonu (loss function) eğitim verileri için

çok küçük, test verileri için çok büyük olduğunda, modelin eğitim verilerine gereğinden fazla uyduğu anlaşılmaktadır (Alawneh ve ark, 2021). Aşırı öğrenme (overfitting) olarak bilinen bu sorunu azaltmak için her iki tam bağlantılı katmandan sonra Dropout katmanı eklenmiştir. Bir ağa seyreltme (dropout) eklemek, aşırı öğrenme olasılığını ve genelleme hatasını önemli ölçüde azaltır (Ravi ve ark, 2016; Verma ve ark, 2022). Seyreltme tekniği (Srivastava ve ark, 2014), yaygın olarak kullanılan bir stokastik düzenleme yöntemidir (Alawneh ve ark, 2021). Eğitim sırasında, gizli katmandaki nöronlar verilen bir olasılık değeri ile rastgele devre dışı bırakılır (Wu ve ark, 2018; Yin ve ark, 2022). Bu modelde Dropout katmanlarındaki seyreltme oranı %10'dur. Son olarak elde edilen çıktı, verilen girdiyi montaj eylemi sayısı (A) kadar sınıfa sınıflandıran softmax aktivasyon fonksiyonuna sahip bir tam bağlantılı (Dense) çıktı katmanına gönderilir.

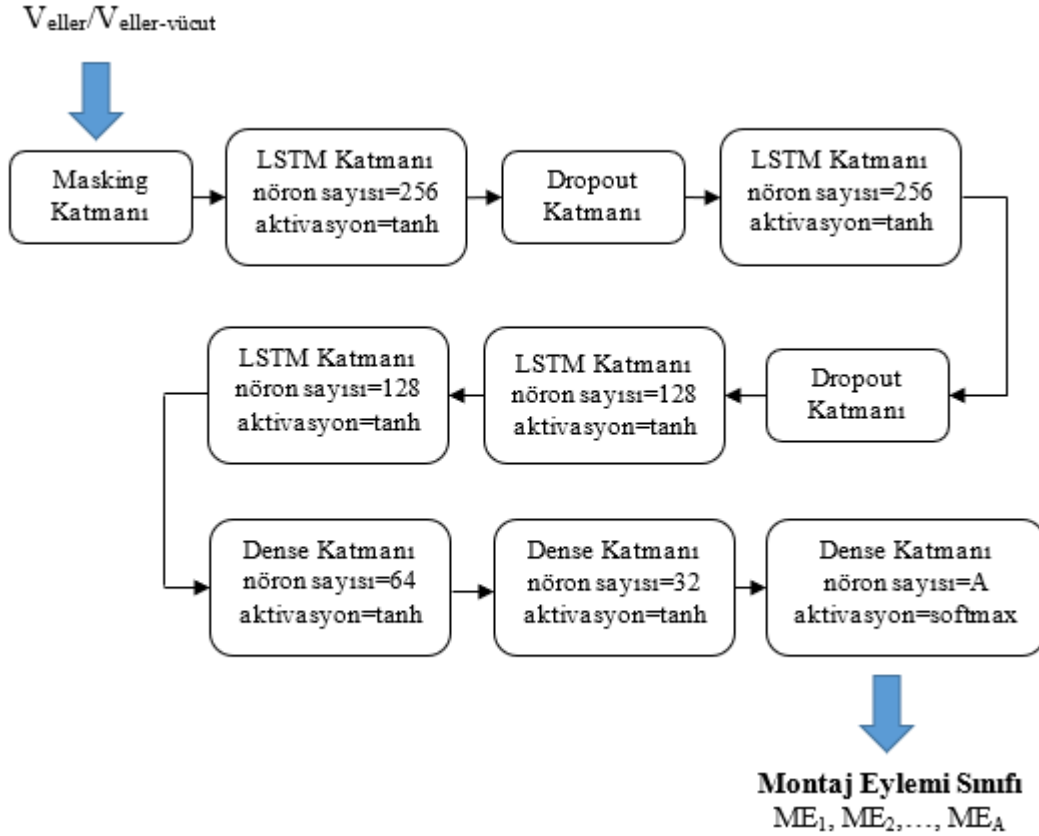


Şekil 4.7. CNN modeli ağ yapısı.

4.4.2. LSTM modeli

LSTM modelinin ağ yapısı Şekil 4.8’de sunulmaktadır. Ağ mimarisi 10 katmandan oluşmaktadır. Modelde maskeleye katmanından sonra sırasıyla 256 nörona sahip 2 LSTM katmanı, 128 nörona sahip 2 LSTM katmanı ve biri 64 nöron diğeri 32 nörona sahip tam bağlantılı sinir ağı katmanı bulunmaktadır. Veri setinde aşırı öğrenmeyi önlemek amacıyla ilk iki LSTM katmanını %50’lik bir Dropout katmanı izlemektedir. 4 LSTM katmanında ve 2 tam bağlı katmanda tanh aktivasyon fonksiyonu

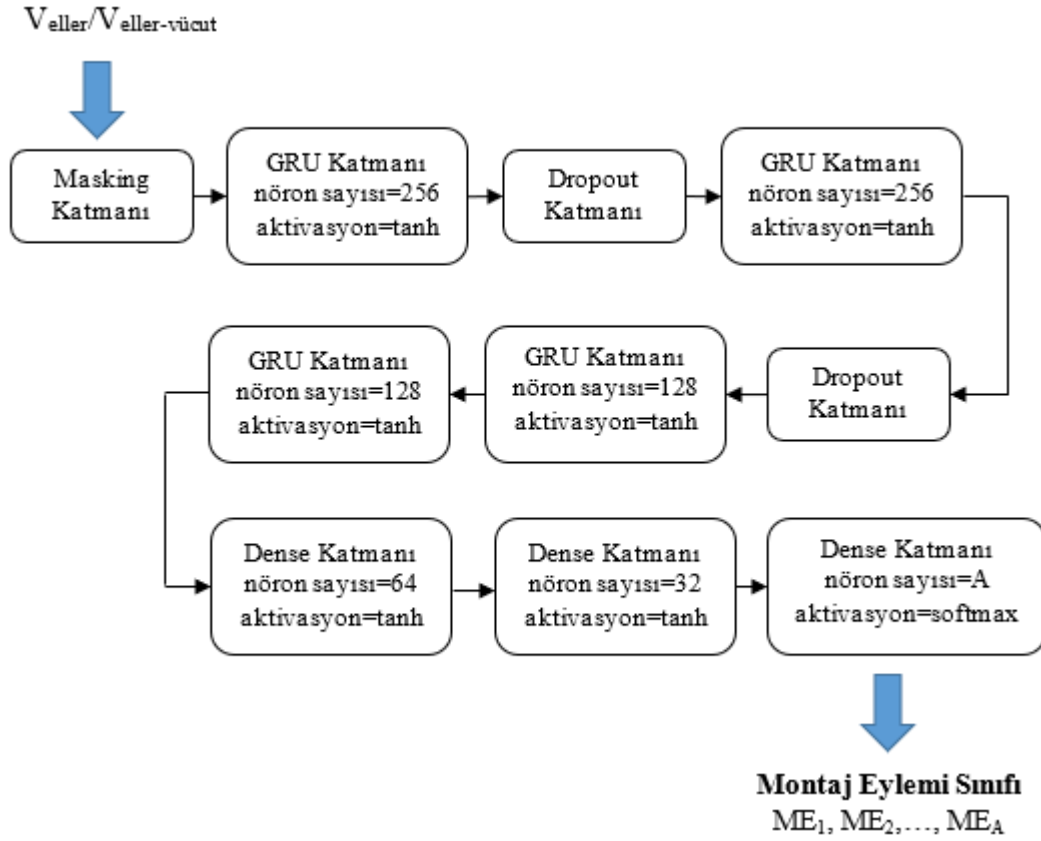
kullanılmıştır. Çünkü derin öğrenme uygulamalarının GPU üzerinde çalışmasını sağlayan NVIDIA CUDA Deep Neural Network (cuDNN) kütüphanesi gereksinimleri LSTM ve GRU katmanlarında sadece tanh aktivasyon fonksiyonunun kullanımını desteklemektedir (Keras Documentation, 2019). Son olarak sınıflandırmanın gerçekleştirilebilmesi için softmax aktivasyon fonksiyonuna sahip montaj eylemi sınıfı sayısı kadar nöronu bulunan bir tam bağlı katman eklenmiştir.



Şekil 4.8. LSTM modeli ağ yapısı.

4.4.3. GRU modeli

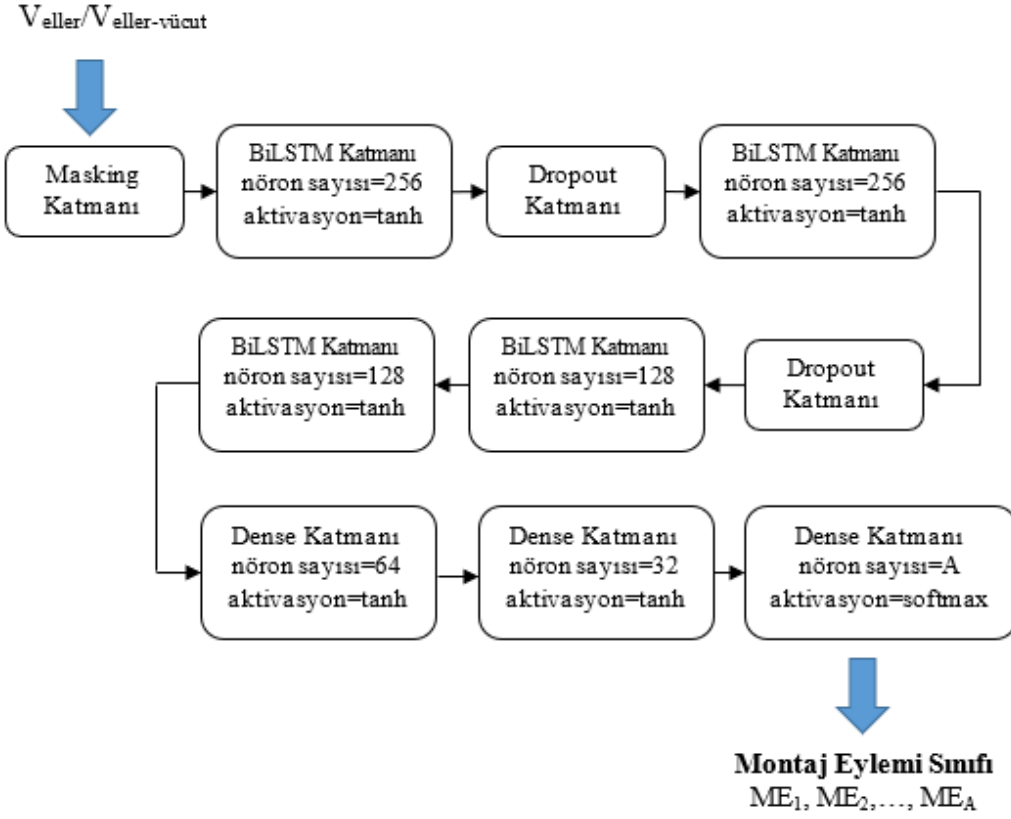
Şekil 4.9’da görüldüğü gibi, LSTM modeline benzer şekilde GRU modelinde 10 katman bulunmaktadır. Maskeleye katmanını sırasıyla, 256 nörona sahip GRU katmanı, %50’lik bir Dropout katmanı, 256 nöronlu GRU katmanı, %50’lik ikinci bir Dropout katmanı, 128 nörona sahip iki GRU katmanı, 64 nöronlu bir tam bağlantılı katman ile 32 nöronlu bir tam bağlantılı katman izlemektedir. GRU ve tam bağlantılı katmanlarda tanh aktivasyon fonksiyonu bulunmaktadır. Son olarak, sınıflandırmanın gerçekleştirileceği montaj eylemi sınıfı sayısı kadar nöronlu ve softmax aktivasyon fonksiyonlu bir tam bağlantılı katman ilave edilmiştir.



Şekil 4.9. GRU modeli ağ yapısı.

4.4.4. Bilstm modeli

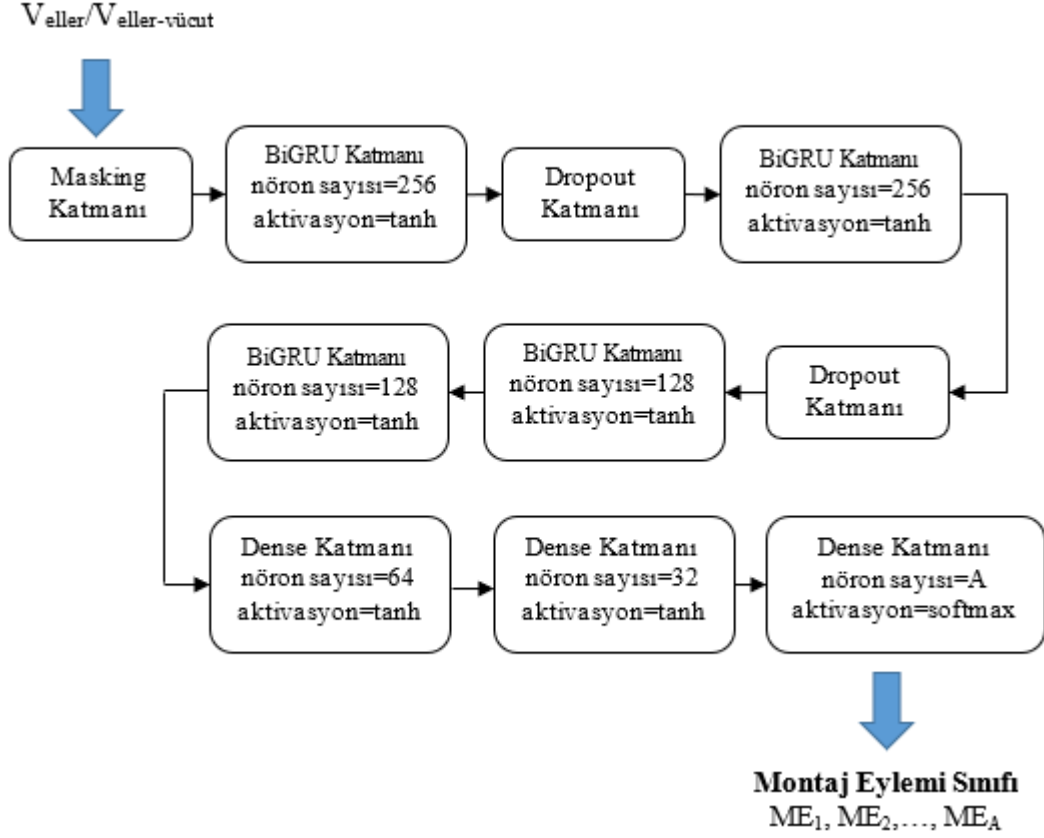
Şekil 4.10’da görüldüğü gibi BiLSTM modeli ağı maskeleye (Masking) katmanı ile başlamaktadır. Maskeleye katmanından sonra 4 BiLSTM Katmanı ve 2 tam bağlantılı katman (Dense) bulunmaktadır. İlk iki BiLSTM katmanınının 256 nöronu bulunmaktadır ve bu katmanları %50 seyreltme oranına sahip birer Dropout katmanı izlemektedir. Daha sonraki iki BiLSTM katmanları 128’er nörona sahiptir. Daha sonra sırasıyla 64 nöronlu ve 32 nöronlu birer tam bağlantılı katman gelmektedir. Tüm katmanlar tanh aktivasyon fonksiyonunu kullanmaktadır. Sınıflandırma için ise en son katman olarak montaj eylemi sınıfı sayısı kadar nörona ve softmax aktivasyon fonksiyonuna sahip bir tam bağlantılı katman eklenmiştir.



Şekil 4.10. BiLSTM modeli ağ yapısı.

4.4.5. Bigru modeli

BiGRU modelinin mimarisi Şekil 4.11’de verilmektedir. Maskeleme katmanından sonra 256 nörona sahip iki adet ve 128 nörona sahip iki adet olmak üzere 4 BiGRU katmanı bulunmaktadır. İlk iki BiGRU katmanından sonra %50’lik Dropout katmanları bulunmaktadır. BiGRU katmanlarından sonra 64 ve 32 nöronlu iki tam bağlantılı katman bulunmaktadır. Her bir katman tanh aktivasyon fonksiyonuna sahiptir. Son katman ise softmax aktivasyon fonksiyonu olan ve montaj eylemi sınıfı sayısı kadar nöronlu tam bağlantılı çıktı katmanıdır.

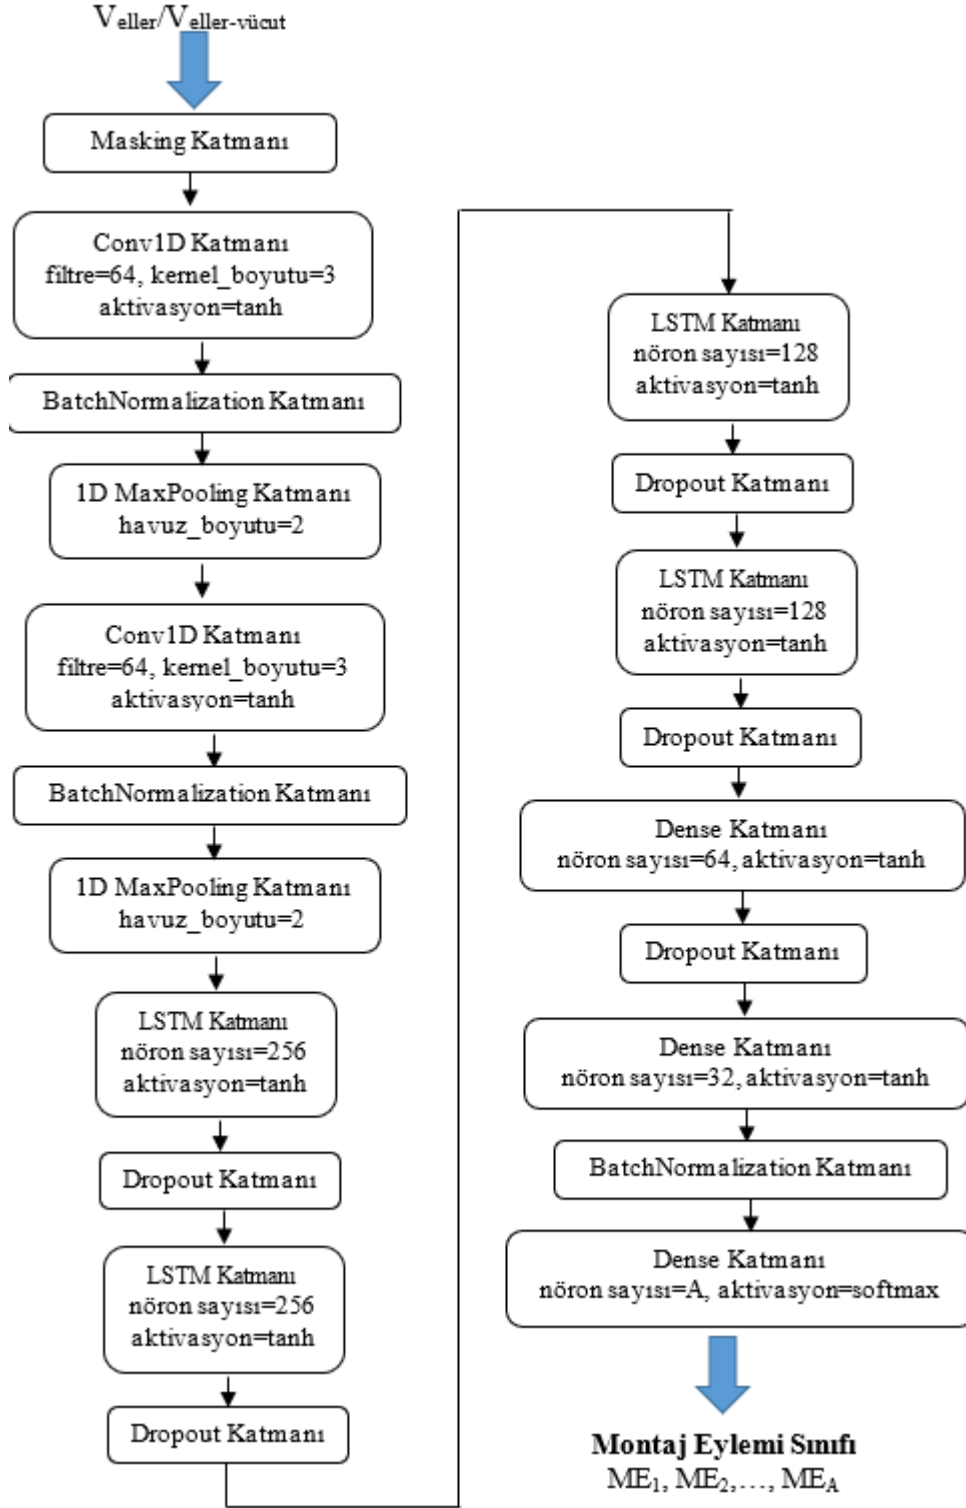


Şekil 4.11. BiGRU modeli ağ yapısı.

4.4.6. CNN-LSTM modeli

20 katmandan oluşan CNN-LSTM modelinin mimarisi Şekil 4.12’de gösterilmektedir. Bu model özellik çıkarımı için tek boyutlu CNN ile LSTM modellerini birleştirir. Maskeleme katmanından sonra 64 filtrelili, çekirdek boyutu 3 olan 1-boyutlu evrişim (Conv1D) katmanı bulunmaktadır. Ardından yığın normalizasyon (BatchNormalization) katmanı gelmektedir. Bu katman daha iyi sınıflandırma verimliliği elde etmek için kullanılır (Verma ve ark, 2022). Eğitim sürecinde, üst katmanın ağırlık parametrelerinin sürekli güncellenmesi nedeniyle her katmanın girdi verilerinin dağılımı sürekli olarak değişecektir. Bu da yakınsama hızının yavaşlaması ile sonuçlanmaktadır (Xia ve ark, 2020). Yığın normalizasyon katmanı, önceki katmanın çıktısının kararlılığını sağlamak için her bir girdi değişkeninin ortalamalarını ve standart sapmalarını hesaplayarak her bir eğitim örneği grubu üzerindeki girdi verilerini normalleştirir (Shalaby ve ark, 2022; Xia ve ark, 2020). Modelin eğitimini ve yakınsamasını hızlandırabilir ve aşırı öğrenmeyi azaltabilir (Lu ve ark, 2022). Bu katmandan sonra havuz boyutu 2 olan 1-boyutlu bir maksimum havuzlama (1D MaxPooling) katmanı eklenmiştir. Daha sonra tekrar sırasıyla, 64 filtrelili, çekirdek

boyutu 3 olan ikinci bir 1-boyutlu evrişim (Conv1D) katmanı, bir yığın normalizasyon (BatchNormalization) katmanı ve havuz boyutu 2 olan 1-boyutlu bir maksimum havuzlama (1D MaxPooling) katmanı daha ilave edilmiştir. Bu katmanları ilk ikisi 256, diğer ikisi 128 nörona sahip 4 LSTM katmanı izlemektedir. Her bir LSTM katmanından sonra %10'luk Dropout katmanı bulunmaktadır. Tüm CNN ve LSTM katmanları tanh aktivasyon fonksiyonuna sahiptir. Bu katmanlardan sonra tanh aktivasyon fonksiyonu kullanan bir 64 nöronlu tam bağlantılı katman ile bir 32 nöronlu tam bağlantılı katman eklenmiştir. İlk tam bağlantılı katmandan sonra %10'luk Dropout katmanı bulunurken ikinci tam bağlantılı katmanı yığın normalizasyon (BatchNormalization) katmanı takip etmektedir. Son katmanda, sınıflandırıcı olarak softmax aktivasyon fonksiyonuna sahip montaj eylemi sınıfı sayısı (A) kadar nöronu bulunan bir tam bağlantılı katman bulunmaktadır.

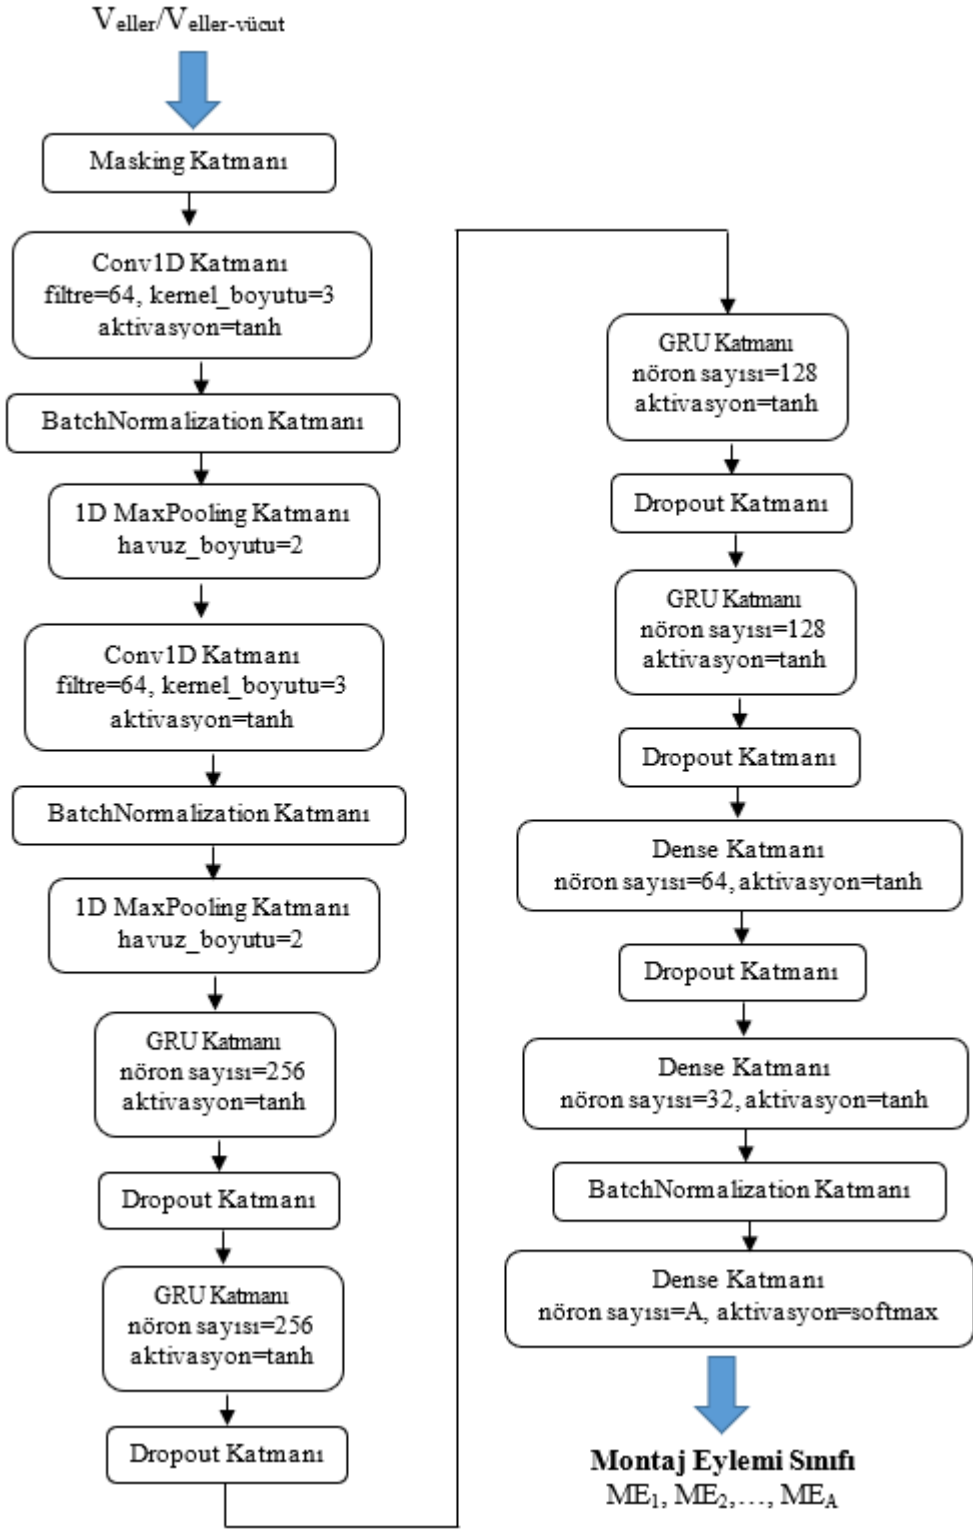


Şekil 4.12. CNN-LSTM modeli ağ yapısı.

4.4.7. CNN-GRU modeli

CNN-GRU modelinin ağ yapısı Şekil 4.13'te verilmektedir. Bu model CNN ve GRU'dan oluşan çok katmanlı bir sinir ağı olarak tasarlanmıştır. CNN-LSTM modeli gibi toplam 20 katmandan oluşmaktadır. CNN-LSTM modelinden farklı olarak

modelden dört LSTM katmanı kaldırılmış, yerlerine aynı nöron sayıları ve tanh fonksiyonuna sahip GRU katmanları eklenmiştir. Maskeleye katmanından sonra iki 1-boyutlu evrişim (Conv1D) katmanı bulunmaktadır. İki evrişim katmanı da 64 filtrelili, çekirdek boyutu 3'tür. Her iki evrişim katmanından sonra sırasıyla yığın normalizasyon (BatchNormalization) katmanı ve 1-boyutlu maksimum havuzlama (1D MaxPooling) katmanı gelmektedir. Maksimum havuzlama katmanlarının havuz boyutları 2'dir. İkinci maksimum havuzlama katmanından sonra dört GRU katmanı kullanılmıştır. Dört GRU katmanının nöron sayısı sırasıyla 256, 256, 128 ve 128'dir. Her bir GRU katmanından sonra %10'luk Dropout katmanı bulunmaktadır. GRU katmanlarından elde edilen sonuçlar montaj eylemlerini sınıflandırmak için kullanılan 3 tam bağlantılı katmana gönderilir. İlk iki tam bağlantılı katman tanh aktivasyon fonksiyonu kullanılır ve sırası ile 64 ve 32 nöronları bulunmaktadır. Son tam bağlantılı katman montaj eylemi sınıfı sayısı kadar nöron barındırır ve softmax aktivasyon fonksiyonu kullanır.

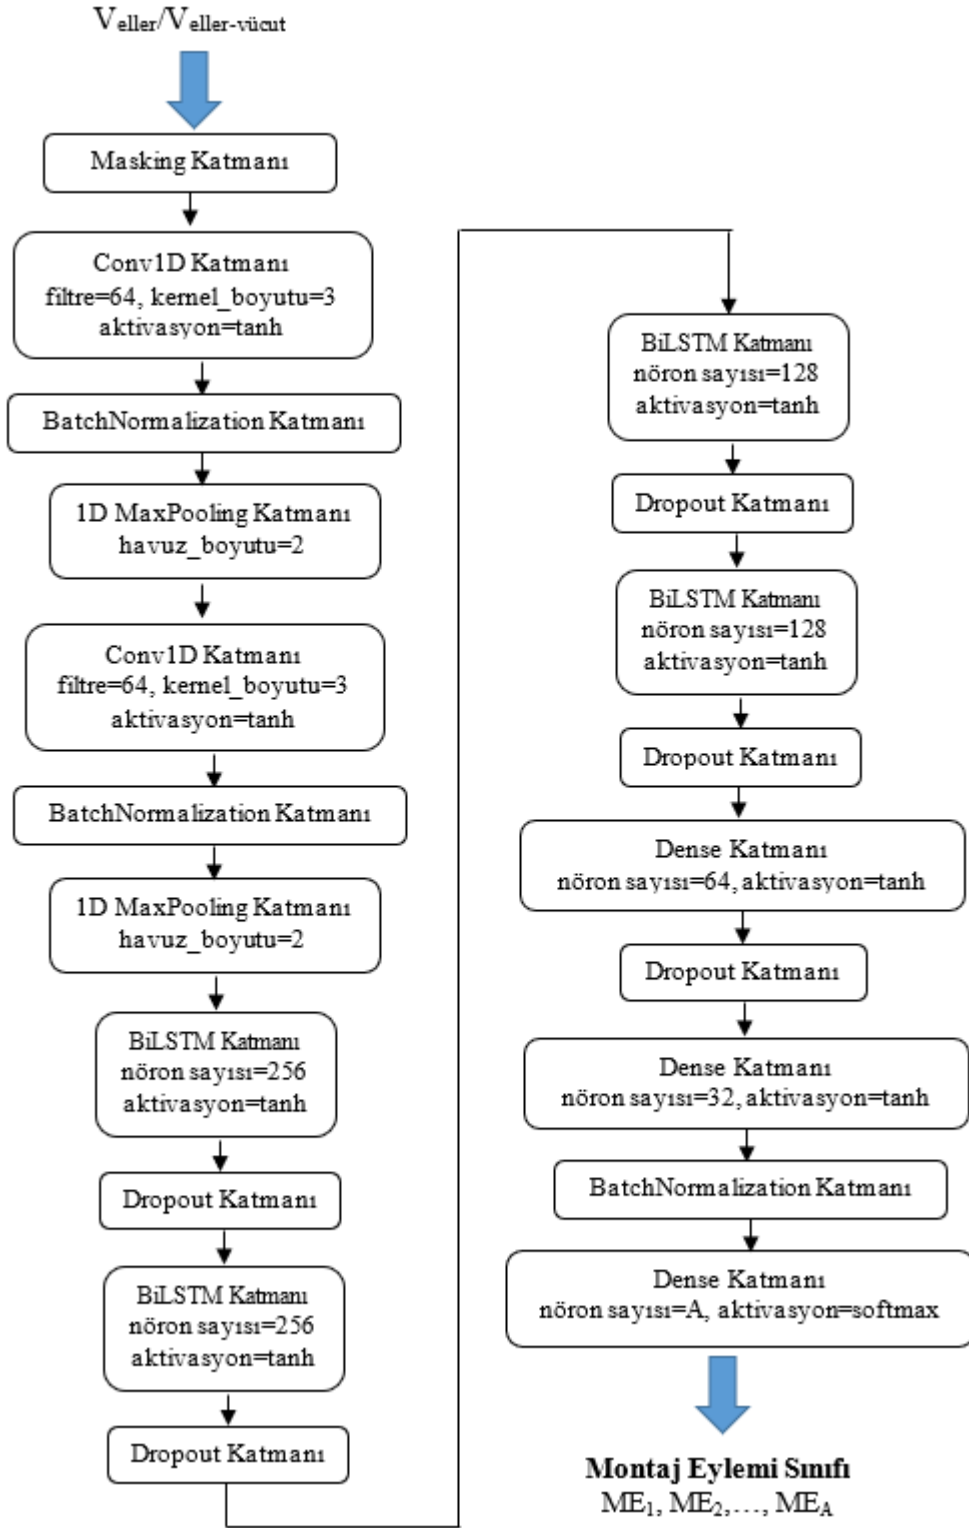


Şekil 4.13. CNN-GRU modeli ağ yapısı.

4.4.8. CNN-bilstm modeli

Bu model CNN ve BiLSTM'in kombinasyonu şeklinde geliştirilmiştir. Şekil 4.14'de görüldüğü gibi CNN-BiLSTM modelinin mimarisi CNN-LSTM ve CNN-GRU modellerinin mimarilerine benzemektedir. Maskeleyen katmanından sonra 3 bölümden

oluşmaktadır. Bu bölümler CNN katmanları bölümü, BiLSTM katmanları bölümü ve tam bağlantılı katmanlar bölümüdür. CNN ve BiLSTM'ler özellik çıkarmadan, tam bağlantılı katmanlar ise sınıflandırmadan sorumludur. Özellik çıkarma kısmı iki 1-boyutlu evrişim (Conv1D) katmanı ve 4 BiLSTM katmanı içermektedir. İki evrişim katmanı da 64 nöronludur ve çekirdek boyutu 3'tür. Her iki evrişim katmanını sırasıyla yığın normalizasyon katmanı ve havuz boyutu 2 olan 1-boyutlu maksimum havuzlama katmanları izler. CNN katmanlarının çıktıları BiLSTM katmanlarına girdi olarak beslenir. BiLSTM katmanlarında sırasıyla 256 nörona sahip bir BiLSTM katmanı, 0,1 oranında seyreltmesi olan bir Dropout katmanı, tekrar 256 nöronlu bir BiLSTM katmanı ve %10'luk bir Dropout katmanı, 128 nöronlu bir BiLSTM ile %10'luk bir Dropout katmanları ve son olarak yine 128 nöronlu bir BiLSTM katmanı ve 0,1 oranında seyreltmesi bulunan bir Dropout katmanı bulunmaktadır. CNN ve BiLSTM katmanları tanh aktivasyon fonksiyonunu kullanmaktadır. BiLSTM katmanlarından sonra eklenen katmanlar 3 tam bağlantılı katman içermektedir. İlk iki tam bağlantılı katmanın nöron sayıları sırasıyla 64 ve 32'dir. Bu katmanlar gizli katmanlar olmakla beraber tanh aktivasyon fonksiyonuna sahiptir. Gizli tam bağlı katmanlardan sonra veri son olarak softmax aktivasyon fonksiyonuna ve montaj eylemleri sınıfı sayısı kadar nörona sahip çıktı katmanı olarak da ifade edilebilen tam bağlantılı sınıflandırıcı katmana gönderilir.

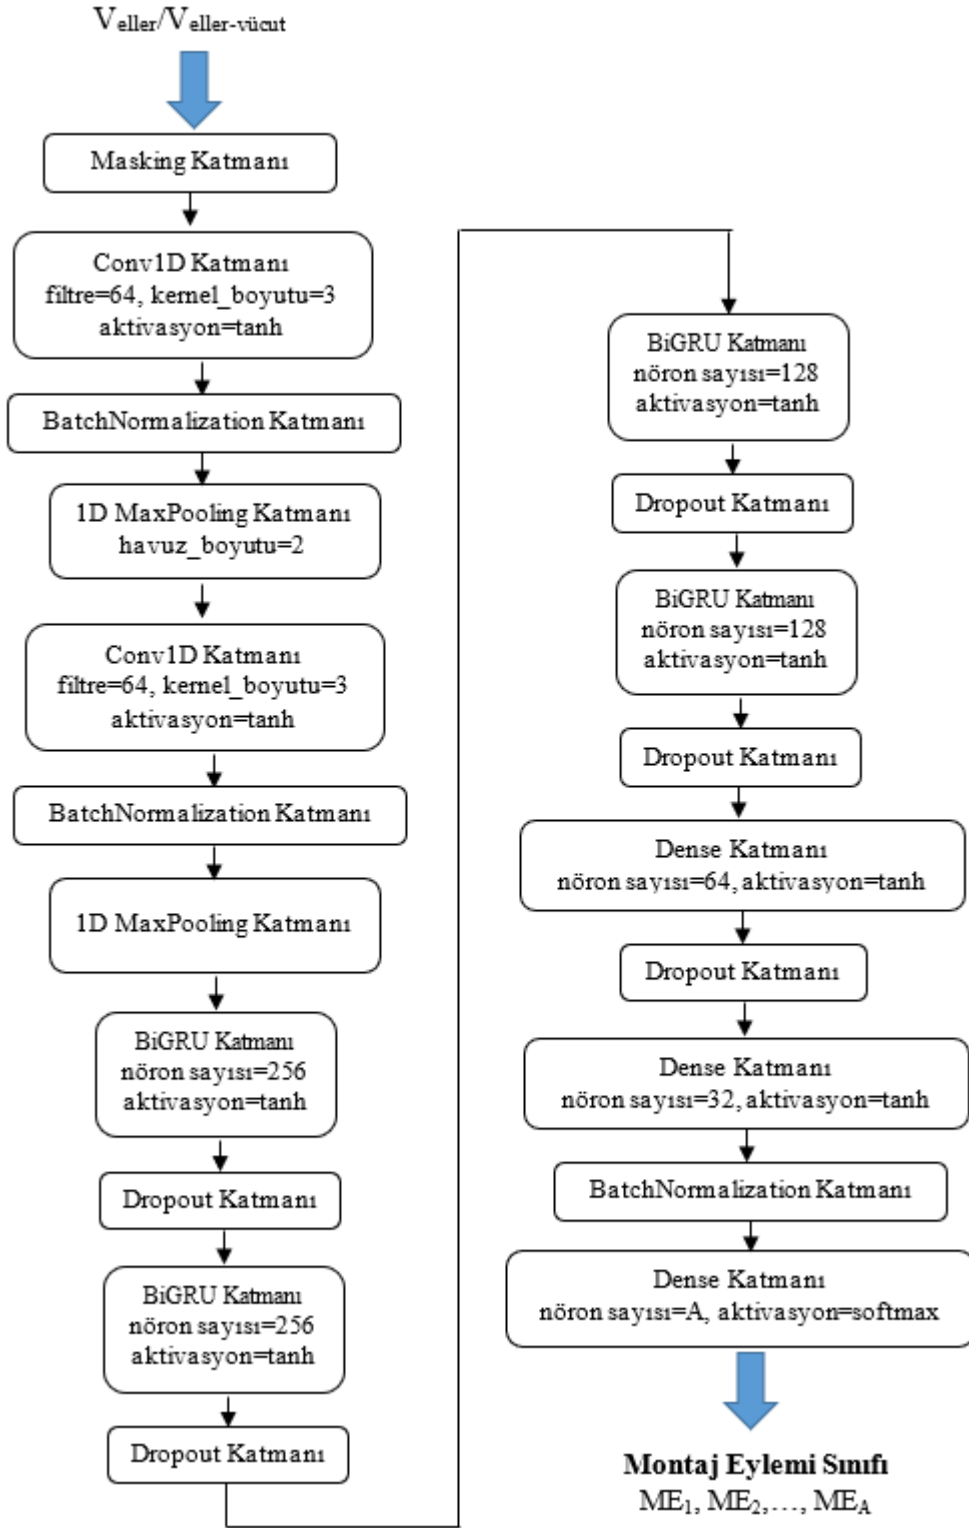


Şekil 4.14. CNN-BiLSTM modeli ağ yapısı.

4.4.9. CNN-bigru modeli

Geliştirilen CNN-BiGRU modelinin ağ yapısı Şekil 4.15'te görülmektedir. Bu modelin yapısı da CNN-LSTM, CNN-GRU ve CNN-BiLSTM modellerin de olduğu gibi üç kısımdan oluşmaktadır. Bu kısımlar giriş, özellik çıkarma ve sınıflandırma

bölümleridir. Verilerin modele girişi diğer modellerde olduğu gibi maskeleyen katman ile sağlanır. CNN ve BiGRU katmanları özellik çıkarma bölümünü oluşturur. Son olarak sınıflandırma bölümü ise tam bağlantılı katmanlar içermektedir. Özellik çıkarma bölümünde 64 filtrelili, çekirdek boyutu 3, adım sayısı 1 olan iki 1-boyutlu evrişim (Conv1D) katmanı, iki yığın normalizasyon katmanı ve havuz boyutu 2 olan iki 1-boyutlu maksimum havuzlama katmanı bulunmaktadır. Evrişim katmanları tanh aktivasyon fonksiyonu kullanmaktadır. Özellik çıkarma bölümünün devamında tanh fonksiyonu kullanan 4 BiGRU katmanı ve her bir BiGRU katmanını takip eden %10'luk birer Dropout katmanları yer almaktadır. BiGRU katmanlarının nöron sayıları sırasıyla 258, 258, 126 ve 126'dır. BiGRU bölümünü ikisi de tanh aktivasyon fonksiyonu kullanan bir 64 nöronlu tam bağlantılı katman ile bir 32 nöronlu tam bağlantılı katman izlemektedir. İlk tam bağlantılı katmandan sonra %10'luk Dropout katmanı, ikinci tam bağlantılı katmandan sonra yığın normalizasyon katmanı bulunmaktadır. Son olarak, sınıflandırma sonuçlarını sağlayan softmax aktivasyon fonksiyonuna sahip montaj eylemi sınıfı sayısı kadar nöronu bulunan bir tam bağlantılı katman eklenmiştir.



Şekil 4.15. CNN-BiGRU modeli ağ yapısı.

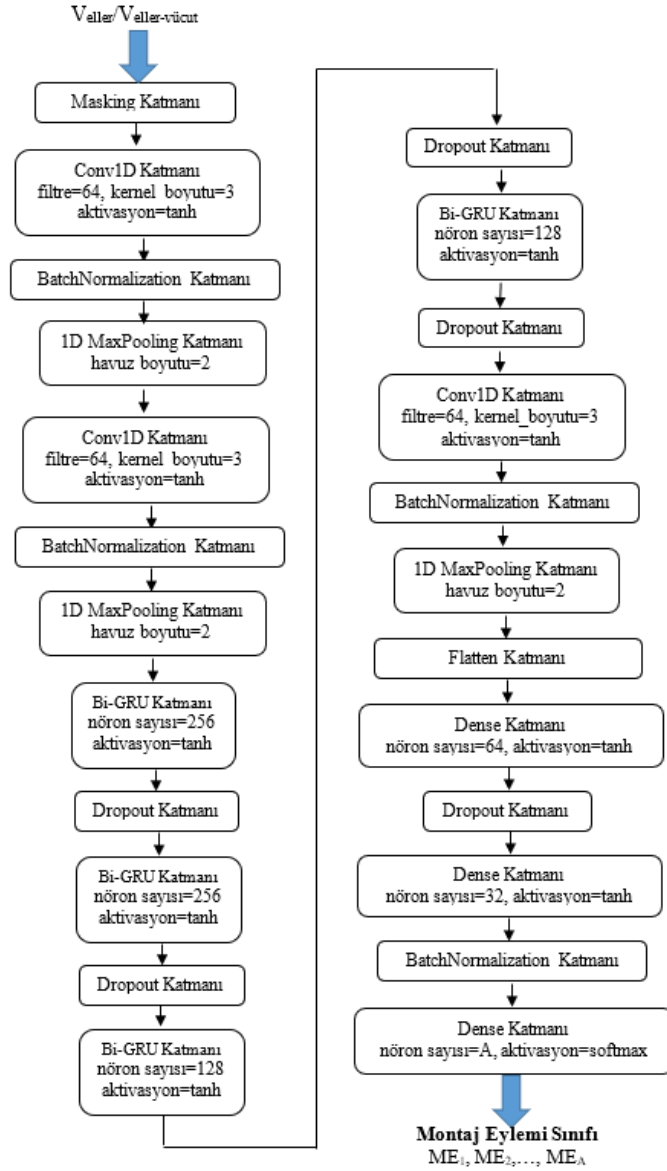
4.4.10. CNN-bigru-CNN modeli

Bu çalışmada önerilen CNN-BiGRU-CNN modeli, maskeleyen katmanından sonra temel olarak dört bölümden oluşan ve CNN ve BiGRU algoritmalarını birleştiren çok katmanlı bir sinir ağı modelidir. Modelin mimarisi Şekil 4.16'da verilmektedir. İlk CNN bölümü otomatik özellik çıkarımı için, BiGRU bölümü zaman serisi özelliklerini çıkarmak için, ikinci CNN bölümü soyut özellikleri genişletmek için kullanılır (Shalaby ve ark, 2022). Tam bağlantı katmanlar bölümü ise doğrusal olmayan bağımlılıkların öğrenilmesi ve sınıflandırma sonuçlarının elde edilmesi için eklenmiştir (Wan ve ark, 2020). İlk CNN bölümünde toplam 6 katman bulunmaktadır. Sıralı verilerin ağı girişini sağlayan maskeleyen katmanından sonra veriler ilk olarak CNN bölümünün ilk katmanı olan 1-boyutlu evrişim (Conv1D) katmanına beslenir. Çekirdek boyutu 3, adım sayısı 1 olan bu katman 64 filtrelidir ve tanh aktivasyon fonksiyonu kullanır. Evrişim katmanını bir yığın normalizasyon (BatchNormalization) katmanı ve havuz boyutu (pool_size) 2 olan 1-boyutlu bir maksimum havuzlama (1D MaxPooling) katmanı izlemektedir. İlk üç katmandan sonra bu katmanlar ile aynı özelliklere sahip bir evrişim katmanı, bir yığın normalizasyon katmanı ve bir maksimum havuzlama katmanı daha ilave edilmiştir. Bu şekilde uzamsal özelliklerin çıkarılmasını sağlayan ağı ilk CNN bölümü tamamlanmaktadır.

CNN katmanlarında çıkarılan özelliklerden zamansal özelliklerin elde edilmesini sağlayan BiGRU bölümü 4 BiGRU katmanından oluşur. Her bir BiGRU katmanından sonra aşırı öğrenmeyi önlemek için 0,1 seyreltme oranına sahip Dropout katmanları eklenmiştir. İlk iki BiGRU katmanının 256 nöronu bulunmaktadır. Diğer iki BiGRU katmanının 128 nöronu vardır. Modeldeki tüm BiGRU katmanları tanh aktivasyon fonksiyonu kullanmaktadırlar. BiGRU bölümünden elde edilen veriler ikinci CNN bölümüne beslenir. İkinci CNN bölümü bir 1-boyutlu evrişim (Conv1D) katmanı, bir yığın normalizasyon (BatchNormalization) katmanı ve bir 1-boyutlu maksimum havuzlama (1D MaxPooling) katmanından oluşmaktadır. Evrişim katmanı 64 filtrelidir. Çekirdek boyutu 3 ve adım sayısı 1'dir. Havuzlama katmanının havuz boyutu 2'dir. Havuzlama katmanından gelen veriler bir düzleştirme katmanı ile düzleştirilerek tam bağlantılı katmanlar bölümüne iletilir.

CNN-BiGRU-CNN özellik çıkarma bölümlerini takip eden tam bağlantılı katman bölümü 2 gizli katman bir çıktı katmanı olmak üzere 3 tam bağlantılı katmandan

oluşur. Gizli tam bağlantılı katmanların aktivasyon fonksiyonu tanh aktivasyon fonksiyonudur ve nöron sayıları sırasıyla 64 ve 32'dir. İlk tam bağlantılı katmandan sonra %10'luk bir Dropout katmanı eklenmiştir. İkinci tam bağlantılı katmanı bir yığın normalizasyon katmanı izlemektedir. Son olarak veriler tüm montaj eylemi sınıflarının tahminini veren tam bağlantılı çıktı katmanına gönderilir. Bu katmanın montaj eylemi sınıfı sayısı kadar nöron sayısı ve softmax aktivasyon fonksiyonu bulunmaktadır.



Şekil 4.16. CNN-BiGRU-CNN modeli ağ yapısı.

4.5. Montaj Eylemlerinin Tanınması Modellerinin Performanslarının Değerlendirilmesi

Bölüm 4.4'te Montaj Eylemlerinin tanınması modeli için geliştirilen modeller arasından en yüksek tahmin başarısına sahip olan model kullanılacaktır. Bu nedenle

geliştirilen modellerin performanslarının karşılaştırılması gerekmektedir. Modellerin karşılaştırılması için literatürde belirli performans kriterleri bulunmaktadır. Montaj eylemlerinin tanınması problemi çok değişkenli sınıflandırma uygulamaları alanına girdiği için bu çalışmada geliştirilen modellerin performanslarının test veri seti üzerinde niceliksel olarak ölçülüp değerlendirilmesinde, sınıflandırma problemlerinde yaygın olarak kullanılan karmaşıklık matrisi, doğruluk skoru, duyarlılık, kesinlik ve F1-Skor kullanılacaktır.

4.5.1. Karmaşıklık matrisi

Herhangi bir sınıflandırma modelinin yeteneğini test etmek için kullanışlı olan birçok metrik bulunmaktadır. Algoritma ve sınıflandırma kuralı performansı ile ilgili tüm bilgileri içerdiğinden, birçok metrik Karmaşıklık Matrisine dayanmaktadır (Grandini ve ark, 2020). A sınıflı bir sınıflandırma problemi için eğitilmiş bir modelin sınıflandırma sonuçları, $A \times A$ boyutunda bir KM karmaşıklık matrisi şeklinde düzenlenebilmektedir. Bu matris, $KM_{v,y}$ ifadesinin y sınıfı olarak sınıflandırılan v sınıfındaki örneklerin sayısı olduğu bir matristir (Labrador ve Yejas, 2013). Bir sınıflandırma modelinin performansını ölçmek için, karmaşıklık matrisinden hareketle 4 muhtemel çıktı elde edilebilmektedir. Bunlar; doğru pozitif (d^p), doğru negatif (d^n), yanlış pozitif (y^p) ve yanlış negatif (y^n) tir (Mirtaheri ve Shahbazian, 2022). Tablo 4.11'de v sınıfının ilgili sınıf veya pozitif koşul olduğu, y sınıfının negatif koşul olduğu varsayıldığında, iki sınıfın bu dört kavramı içeren basitleştirilmiş karmaşıklık matrisi verilmektedir. Satırlar, gerçek sınıfları, sütunlar ise tahmin edilenleri temsil etmektedir (Ortiz, 2014). Bu karmaşıklık matrisinde, d^p ve d^n , doğru şekilde sınıflandırılan pozitif ve negatif örneklerin sayısını gösterirken, y^p ve y^n , sırasıyla yanlış sınıflandırılan negatif ve pozitif örneklerin sayısını gösterir (Hossin ve Sulaiman, 2015).

Tablo 4.11. 2 X 2 boyutlu karmaşıklık matrisinin bir gösterimi (Ortiz, 2014).

		Tahmin Edilen Sınıf	
Gerçek Sınıf	v (pozitif)	y (negatif)	
v (pozitif)	d^p	y^n	
y (negatif)	y^p	d^n	

Bu değerler baz alınarak doğruluk skoru, duyarlılık, kesinlik ve F1-Skor başta olmak üzere çeşitli istatistiksel sınıflandırma performans ölçütleri hesaplanmaktadır.

4.5.2. Doğruluk, kesinlik, duyarlılık ve f1-skor

Doğruluk, tüm sınıflar için genel sınıflandırma performansını özetleyen en standart metriktir ve doğru sınıflandırılmış örneklerin toplam örnek sayısına oranı olarak tanımlanmaktadır (Labrador ve Yejas, 2013; Tharwat, 2021). Simetrik ve dengeli veri setleri üzerinde çalışıldığında doğruluk oldukça iyi bir ölçüdür. Fakat yanlış pozitif hatalar ile yanlış negatif hatalar arasında ayrım yapmaz. Ayrıca, sınıfların oranlarının popülasyonda çarpık olduğu veri setlerinde doğruluk bilgilendirici bir ölçüm değildir. Dengesiz test veri setleri için doğruluk skorunun yanı sıra model performansını ifade eden kesinlik, duyarlılık ve F1-Skor gibi başka metrikler de kullanılmaktadır (Hackeling, 2017; Mirtaheri ve Shahbazian, 2022).

Kesinlik ölçütü, doğru pozitif tahminlerin sayısının toplam pozitif tahmin sayısına oranı olarak hesaplanmaktadır. Duyarlılık ölçütü ise, doğru pozitif tahminlerin sayısının toplam doğru pozitiflerin sayısına oranı ile hesaplanmaktadır (Dang, 2022). 1'e yakın yüksek bir kesinlik değeri ve yüksek bir duyarlılık değeri elde etmek iyi olarak kabul edilmektedir (Lindholm ve ark, 2022). Kesinlik ve duyarlılığı tek bir istatistikle özetleyen F1-Skor kesinlik ve duyarlılığın harmonik ortalamasıdır (Hackeling, 2017).

A sınıflı bir çok sınıflı montaj eylemlerinin sınıflandırılması probleminde, $ME = \{ME_1, ME_2, \dots, ME_a, \dots, ME_A\}$ deney için düşünülen montaj eylemi sınıfları kümesi olduğunda, her bir ME_a sınıfı için doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif değerleri sırasıyla d_a^p , d_a^n , y_a^p ve y_a^n ile ifade edilsin. Çok sınıflı montaj eylemlerinin sınıflandırılması problemleri için kullanılacak ortalama doğruluk,

kesinlik, duyarlılık ve F1-Skor performans ölçütlerinin formülleri Tablo 4.12’de verilmektedir.

Tablo 4.12. Çok sınıflı sınıflandırma problemlerinde kullanılacak performans ölçütleri (Hossin ve Sulaiman, 2015).

Performans Ölçütü	Formül
Doğruluk	$\frac{1}{A} \sum_{a=1}^A \frac{d_a^p + d_a^n}{d_a^p + d_a^n + y_a^p + y_a^n}$
Kesinlik (K^M)	$\frac{1}{A} \sum_{a=1}^A \frac{d_a^p}{d_a^p + y_a^p}$
Duyarlılık (D^M)	$\frac{1}{A} \sum_{a=1}^A \frac{d_a^p}{d_a^p + y_a^n}$
F1-Skor	$\frac{2 * K^M * D^M}{K^M + D^M}$

4.6. Gerçek Zamanlı Uygulama

Bu aşamaya kadar geliştirilen montaj eylemlerinin tanınması modeli Zeki Seru Üretim Sisteminin Bileşen 1, Bileşen 4, Bileşen 5 ve Bileşen 6 olmak üzere dört bileşenin bünyesinde kullanılabilmektedir. Bu bölümde sistem bileşenin parçası olan montaj eylemlerinin tanınması modeli için bir gerçek zamanlı çalışma algoritması önerilmiştir. Önerilen algoritma Tablo 4.13’te sunulmaktadır. Sistem iteratif bir şekilde her bir j zaman adımında çevrimiçi tahmin üretmek üzere çalışacak şekilde tasarlanmıştır. Öncelikle, önerilen metodolojiye ait verilerin toplanması ve düzenlenmesi adımında detayları verildiği gibi çalışan/çalışanların ardı ardına montaj eylemlerini gerçekleştirdiği montaj sürecinden çalışan başına bir kamera ile h=15 fps hızında, H × W resim çözünürlüğünde görüntüler toplanır. Her bir zaman adımında kamera ile alınan görüntünün poz verileri MediaPipe Holistic kütüphanesi kullanımı ile elde edilerek, I_t (girdi niteliği sayısı) boyutunda d_j vektörü oluşturulur. WS pencere büyüklüğü olmak üzere, çalışmada geliştirilen model $WS * I_t$ boyutunda örnekler üzerinde eğitildiği için her bir zaman adımında elde edilen d_j vektörlerinden oluşan WS büyüklüğünde V girdi veri seti oluşturulur. Yani V veri seti WS adet zaman adımı verileri içeren bir penceredir. Sistem çalışmaya başladığında oluşturulan ilk pencereler (ilk WS zaman adımına kadar) poz verileriyle doldurulmayı beklemek zorunda

olacağından, WS adıma kadar sistem bir çıkarımda bulunamayacak, bu nedenle WS/15 saniye kadar bir başlangıç gecikmesi oluşacaktır. Bu gerçek zamanlı uygulamalar için önemli bir sorundur. Han ve ark. (2021), bu sorunu azaltmak için 0,5 saniyelik pencereyi kullanıcının bir aktiviteye başlamadan 0,3 saniye önceki sensör verileri ile doldurmuşlardır. Bu tez çalışmasında başlangıç gecikmesinin oluşumunu önlemek için, ilk WS zaman adımına kadar elde edilen V pencereleri verilen bir p dolgu değeri ile doldurulur. Bu şekilde sistemin ilk başladığı zaman adımından itibaren tahmin üretebilmesi sağlanır. V veri setinde d_j poz verileri ilk giren ilk çıkar mantığı ile saklanmaktadır. Yani her bir zaman adımında V veri setine d_j poz verileri vektörü eklendikçe d_{j-WS+1} vektörü V veri setinden çıkartılır. İşlemler sonucunda her bir zaman adımında elde edilen $WS \cdot I_t$ boyutundaki V penceresi çalışmada geliştirilen derin öğrenmeye dayalı montaj eylemlerinin tanınması modeline girdi olarak verilerek modelin çevrimiçi tahminde bulunması sağlanır. Bu şekilde çalışanın her bir zaman adımında gerçekleştirmekte olduğu montaj eyleminin gerçek zamanlı tahmini (E_{tj}) elde edilmiş olur.

Tablo 4.13. Montaj eylemlerinin tanınması modelinin gerçek zamanlı çalışma algoritması adımları.

Algoritma 6. Önerilen Montaj Eylemlerinin Tanınması Modeli Algoritması

Girdi G_j – Girdi videosunun j. çerçevesi,

h – saniye başına düşen kare sayısı

H – görüntü çözünürlüğünün yükseklik boyutu

W – görüntü çözünürlüğünün genişlik boyutu

WS – pencere büyüklüğü,

p – dolgu değeri

Çıktı j – video çerçevesi numarası

E_{tj} – j. zaman adımında tahmin edilen montaj eylemi

1: $V \leftarrow \{\}$

2: $j=0$

3: do

4: $d_j \leftarrow \{\}$

5: $G_j \leftarrow \text{GORUNTUAL}(h,H,W)$ //Her bir zaman adımında görüntülerin okunması

Tablo 4.13. (Devamı) Montaj eylemlerinin tanınması modelinin gerçek zamanlı çalışma algoritması adımları.

Algoritma 6. Önerilen Montaj Eylemlerinin Tanınması Modeli Algoritması

6: $d_j \leftarrow \text{POZTAHMİNİ}(G_j)$ // kilit nokta değerleri için poz tahmini modelinin uygulanması
7: $V \leftarrow V \cup d_j$
8: if $\text{uzunluk}(V) < WS$
9: $V = \text{DOLDUR}(V, WS, p)$ // dolgu işleminin uygulanması
10: else if $\text{uzunluk}(V) > WS$
11: $V = V - d_{j-WS+1}$ // sabit pencere uzunluğunun elde edilmesi
12: $E_t \leftarrow \text{TAHMINET}(V)$ // geliştirilen derin öğrenme modeli ile eylemin tahmin edilmesi

5. MONTAJ EYLEMLERİNİN TANINMASI MODELİNİN UYGULAMASI

Bu bölümde, montaj eylemlerinin tanınması modelinin çalışma metodolojisi gerçek bir üretim ortamında uygulanmış ve sonuçları tartışılmıştır.

Montaj eylemlerinin tanınması modelinin çalışma metodolojisi adımları bir önceki bölümde verilmiştir. Bu bölüm kapsamında metodoloji adımlarından montaj eylemlerinin tanınması modelinin geliştirilmesini kapsayan ilk 5 aşamanın detayları verilmektedir. Bu çalışmada önerilen modelin farklı parametrelerde (doğruluk skoru, duyarlılık, kesinlik, F1-Skor performans ölçütleri) performansını değerlendirmek için montaj hattı ve serü üretim sisteminde geliştirilecek iki modelin karşılaştırılması yapılarak sonuçları değerlendirilecektir. Önerilen metodolojinin etkinliği ilk olarak montaj hattında değerlendirilecektir. Daha sonra aynı ürünün montajına yönelik serü üretim sisteminde montaj sürecinin görüntüleri alınarak önerilen metodoloji uygulanacaktır. İki montaj sisteminden elde edilen sonuçlar karşılaştırılacaktır.

Geliştirilen kavramsal modelin uygulaması için elektromekanik endüstrisi seçilmiş ve bu sektörde ürün üreten Federal Elektrik firmasının montaj bölümünde gerekli görüşme ve sözleşmeler yapıldıktan sonra çalışmalara başlanmıştır. Çalışma Sakarya Üniversitesi Fen ve Mühendislik Bilimleri Etik Kurulu'nun 18.01.2023 tarih ve 32 sayılı kararı ile Etik Kurulun izni (EK A.1-A.2) alınarak gerçekleştirilmiştir. Tez çalışması, Sakarya Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü Birimi tarafından 2022-7-25-38 proje numarası ile desteklenmiştir.

5.1. Sistemin Tanıtımı

Önerilen sistemin geliştirilmesi için seçilen bir ürününün montaj süreci üzerine veriler alınmıştır. Ürünün montaj süreci toplam 15 montaj işleminden ($ME_1, ME_2, \dots, ME_{15}$) oluşmaktadır. Montaj sürecinde $MB = (MB_1: \text{mafsal açtırma yayı}, MB_2: \text{mafsal}, MB_3: \text{kurma kolu U pimi}, MB_4: \text{kurma kolu yayı}, MB_5: \text{setiskür}, MB_6: \text{kurma kolu}, MB_7: \text{klemens}, MB_8: \text{seperatör}, MB_9: \text{örgü mili}, MB_{10}: \text{manyetik}, MB_{11}: \text{bobin}, MB_{12}: \text{örgü}, MB_{13}: \text{kapak}, MB_{14}: \text{gövde})$ olmak üzere toplam 14 montaj bileşeni ve $MA = (MA_1: \text{kargaburun}, MA_2: \text{tokmak}, MA_3: \text{alyan}, MA_4: \text{tornavida})$ olmak üzere toplam 4 montaj

aleti kullanılmaktadır. Süreç, birleşik halde bulunan MB₁₃ ve MB₁₄'ün birbirinden ayrılması ile başlar, ardından küçük boyutlu olan MB₅, MB₄, MB₆, MB₁₁, MB₇, MB₁₀, MB₉, MB₁₂, tekrar bir MB₇, MB₈, MB₂, MB₃ ve MB₁ MB₁₄'e sırasıyla monte edilir. MB₅ ile bimetal ayarı yapıldıktan sonra MB₁₄ ile MB₁₃ birleştirilir ve kurma testi yapılır. Tablo 5.1'de montaj sürecine ait montaj işlemleri bilgileri, montaj işlemlerinde kullanılan ürün bileşenleri ve montaj aletleri verilmektedir.

Tablo 5.1. Üzerinde çalışılan montaj sürecine ait bilgiler.

Montaj Eylemi	Açıklama	Bileşenler	Aletler
ME ₁	Gövde açma	MB ₁₃ , MB ₁₄	-----
ME ₂	Bimetal setüskür montajı	MB ₅	MA ₂
ME ₃	Kurma kolu yayı montajı	MB ₄	MA ₃
ME ₄	Kurma kolu montajı	MB ₆	-----
ME ₅	Bobin, klemens ve manyetik montajı	MB ₁₁ , MB ₇ , MB ₁₀	MA ₂
ME ₆	Örgü mili montajı	MB ₉	-----
ME ₇	Örgü montajı	MB ₁₂	MA ₄
ME ₈	Klemens montajı	MB ₇	MA ₂ , MA ₃
ME ₉	Seperatör montajı	MB ₈	-----
ME ₁₀	Mafsal montajı	MB ₂	-----
ME ₁₁	Kurma kolu U pimi montajı	MB ₃	-----
ME ₁₂	Mafsal açtırma yayı montajı	MB ₁	-----
ME ₁₃	Setiskür ile bimetal ayarı	-----	MA ₃ , MA ₁
ME ₁₄	Gövde kapatma	MB ₁₃ , MB ₁₄	-----
ME ₁₅	Kurma testi	-----	-----

Tablo 5.1’de görüldüğü gibi çoğu montaj işleminde 1 montaj bileşeni, ME₁ ve ME₁₄’te 2 montaj bileşeni, ME₅’te 3 montaj bileşeni kullanılmaktadır. ME₁₃ ve ME₁₅’te ise herhangi bir montaj bileşeni kullanılmamaktadır. Montaj aleti kullanım sayıları incelendiğinde ise, benzer şekilde ME₂, ME₃, ME₅ ve ME₇’de 1, ME₈ ve ME₁₃’te 2 montaj aleti kullanıldığı görülmektedir. Diğer montaj eylemlerinde ise hiç montaj aleti kullanılmamaktadır. Görüldüğü gibi ME₁₅ montaj eyleminde herhangi bir montaj bileşeni veya montaj aleti kullanımı bulunmamaktadır. Bu nedenle montaj süreci, nesne tespiti ile gerçekleştirilen montaj eylemi sınıflandırma çalışmalarına uymamaktadır. Üzerinde çalışılan montaj sürecinin doğası gereği, montaj eylemlerinin sınıflandırılabilmesi için hareket verilerine ihtiyaç bulunmaktadır.

5.2. Sistem Gereksinimleri

Uygulamaların gerçekleştirilebilmesi için sistem gereksinimleri donanım ve yazılım gereksinimleri olmak üzere iki bölümden oluşmaktadır. Uygulama adımlarının ihtiyaçları doğrultusunda iki farklı donanım seti kullanılmıştır:

- 1- Video görüntülerinin toplanması esnasında, montaj hattında istasyonlarda bulunan her bir çalışanın, serü üretim sisteminde ise yataide bulunan bir çalışanın karşısında çalışanın tüm faaliyetlerini ve montaj sürecindeki tüm bileşenleri kapsayabilecek şekilde tripod üzerine sabitlenen Logitech C920 HD Pro Webcam kullanılmıştır. Kamera, 2.40 GHz Intel(R) Core(TM) i5-4210U CPU işlemci ve 8 GB RAM’e sahip bir dizüstü bilgisayara bağlanmıştır.
- 2- Verilerin düzenlenmesi, poz tahmini, verilerin hazırlanması ve derin öğrenme modellerinin eğitimi ve test edilmesi aşamasında 11th Gen Intel(R) Core(TM) i7-11700 2.50 GHz işlemci, 64 GB RAM ve NVIDIA GeForce GTX 1660 SUPER GPU'ya sahip bir iş istasyonu kullanılmıştır. İş istasyonu 64 bitlik bir Windows işletim sistemi ile donatılmıştır. Derin öğrenme uygulamaları GPU üzerinde çalışmayı sağlayan NVIDIA CUDA (10.1 sürüm) ve NVIDIA CUDA Deep Neural Network (cuDNN) (7.6 sürüm) kullanılarak gerçekleştirilmiştir.

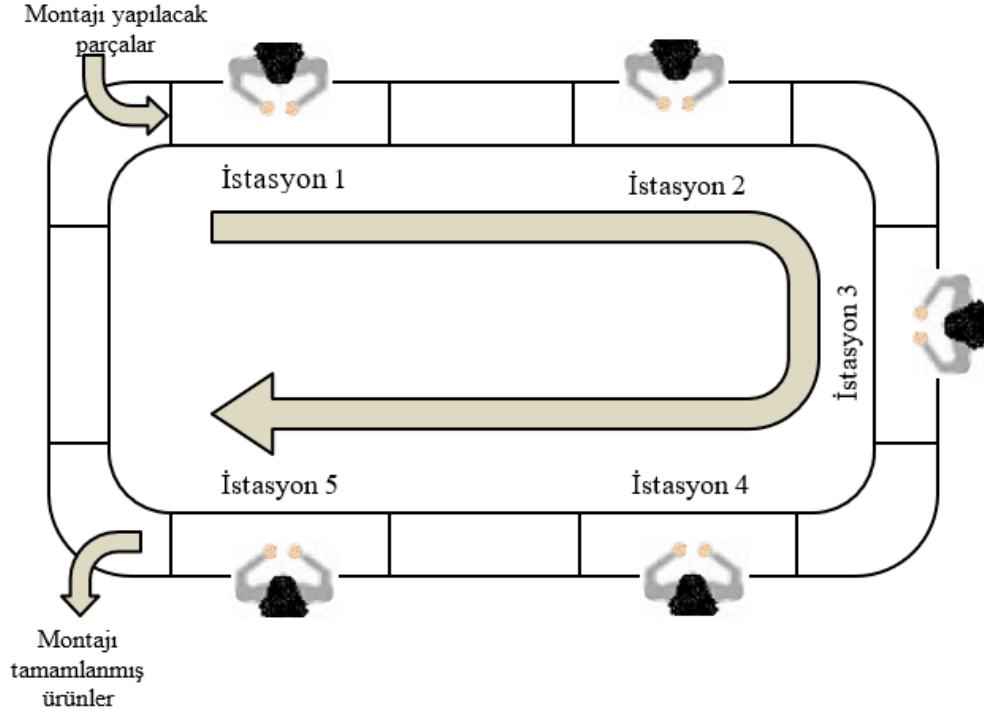
Yazılım geliştirme aşamasında ise Spyder ortamında Python (3.8 sürüm) dili kullanılmıştır. Uygulama adımlarının gereksinimleri doğrultusunda kullanılan kütüphaneler şu şekildedir:

- Opencv (4.5.5 sürüm) kütüphanesi: Gerçek-zamanlı görüntü işleme uygulamaları için geliştirilmiş açık kaynaklı kütüphanedir.
- MediaPipe kütüphanesi: Google tarafından geliştirilmiş ve nesne tespiti, yüz tespiti, yüz kilit noktaları tespiti, el kilit noktaları tespiti, vücut kilit noktaları tespiti, görüntü segmentasyonu gibi gelişmiş yapay zeka ve makine öğrenmesi destekli uygulama çözümleri sunan açık kaynaklı bir altyapıdır.
- Numpy (1.18.5 sürüm) kütüphanesi: Sayısal veriler ile çalışmayı sağlayan, çok boyutlu dizi ve matris veri yapılarını içeren açık kaynaklı bir kütüphanedir.
- Keras kütüphanesi: Tensorflow makine öğrenmesi platformu üzerine inşa edilmiş olan Keras kütüphanesi, yüksek iterasyon hızına sahip derin öğrenme arabirimidir.
- Scikit-learn (1.1.1 sürüm) kütüphanesi: Python programlama dili için geliştirilmiş tahminsel veri analizi için araçlar sunan, makine öğrenmesi kütüphanesidir.
- Seaborn (0.11.2. sürüm) kütüphanesi: Python programlama dili için veri görselleştirme kütüphanesidir.

İlgili kütüphanelerin kullanım detayları gerekli aşamalarda anlatılmaktadır.

5.3. Montaj Hattında Uygulama

Firmada ürünün montajı için Şekil 5.1’de yerleşimi gösterilen 5 istasyonlu bir montaj hattı sistemi kullanılmaktadır. Her bir istasyonda yaşları 18-43 arasında değişen birbirinden farklı tek bir çalışan bulunmaktadır.



Şekil 5.1. Uygulamanın gerçekleştirildiği montaj hattının yerleşimi.

Montaj hattında istasyonlarda gerçekleştirilen montaj görevleri Tablo 5.2’de verilmektedir. Çalışanların montaj süreci boyunca kullanacakları montaj bileşenleri ve montaj araçları kendilerine ait istasyonlarda hazır bulunmaktadır. Hatta herhangi bir tikanıklık olması durumunda hat durdurulmaktadır.

Tablo 5.2. Montaj hattında istasyonlarda gerçekleştirilen görevler.

İstasyon	Montaj Görevleri
1. istasyon	ME ₁ -ME ₂ -ME ₃ -ME ₄
2. istasyon	ME ₅ -ME ₆
3. istasyon	ME ₇ -ME ₈
4. istasyon	ME ₉ - ME ₁₀ - ME ₁₁ - ME ₁₂
5. istasyon	ME ₁₃ - ME ₁₄ - ME ₁₅

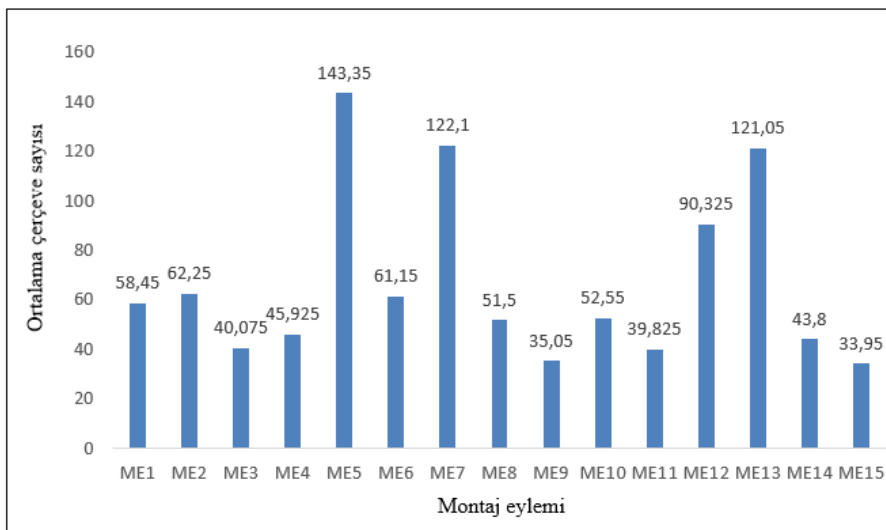
5.3.1. Verilerin toplanması ve düzenlenmesi

Montaj eylemlerinin tanınması modelinin montaj hattı sisteminde geliştirilmesi amacıyla, firmada üretim ortamında mevcut kurulu bulunan montaj hattı sisteminden, 40 adet ürün için her bir çalışanın kendisine ait montaj görevlerini ardı ardına

gerçekleştirmekte olduğu her biri farklı sürelerle sahip on beş montaj işleminin video görüntüleri sistem gereksinimleri bölümünde detayları verilen kamera, tripod ve dizüstü bilgisayar yardımıyla toplanmıştır. Toplanan video görüntüleri verileri Opencv (4.5.5 sürüm) kütüphanesi kullanılarak geliştirilen kod bloğu kullanılarak 1920 x 1080 piksel çözünürlükte 30 fps hızı ile istasyon başına bir video olacak şekilde 5 video halinde bilgisayara kaydedilmiştir. Bu şekilde, montaj hattına ait montaj eylemi görüntü veri seti oluşturulmuştur.

Kaydedilen 5 video, her bir ürünün (40 ürün) her bir işlemi (15 montaj eylemi) için Windows Fotoğraflar uygulaması kullanılarak kırılmış ve 1280 x 720 piksel çözünürlükte kaydedilerek 600 adet yeni video elde edilmiştir. Videoların saklanması için MH_Video isminde bir klasör oluşturulmuştur. Bu klasör içerisine ürün sayısı kadar (40) boş klasör eklenmiştir. Her bir ürün için 15 montaj eylemine ait videolar bu klasörlerin içerisine konulmuştur. Ayrıca, elde edilecek olan poz verilerinin saklanması için bu klasörlerin içerisine 15 adet boş klasör açılmıştır.

Her bir üründeki her bir işlem videosunun çerçeve sayısı Spyder ortamında Opencv kütüphanesi kullanılarak geliştirilen Python kod bloğu kullanılarak elde edilmiştir. Montaj hattı sisteminde gerçekleştirilen montaj eylemlerinin ortalama çerçeve sayıları Şekil 5.2’de verilmektedir. Şekilde görüldüğü gibi veri setindeki montaj eylemleri birbirlerinden oldukça farklı çerçeve sayılarından, dolayısıyla farklı sürelerden oluşmaktadır. Ortalama olarak, ME₅ işleminin tamamlanması en uzun süreyi alırken, ME₁₅ işleminin tamamlanması en kısa süreyi almaktadır.



Şekil 5.2. Montaj hattı görüntü veri setindeki her bir montaj eylemi için ortalama çerçeve sayıları.

5.3.2. Poz tahmini


Bu çalışmada, çalışanların her bir çerçevede 3B poz verisini tahmin etmek için MediaPipe kütüphanesinin MediaPipe Holistic modelinden yararlanılmıştır. Öncelikle Opencv kütüphanesi yardımıyla video çerçeveleri BGR formatından RGB formatına dönüştürülmüştür. Video verisinden çalışanın kilit noktalarının koordinatları ardışık çerçevelerdeki kilit noktaları izlemek için 0,5 minimum algılama güven değeri ve 0,5 minimum izleme güven değeri kullanılarak Spyder geliştirme ortamında MediaPipe Holistic Python uygulaması aracılığıyla elde edilmiştir. Videolar Opencv kütüphanesi yardımıyla buldukları klasörlerden okunarak videoları oluşturan her bir çerçeve için MediaPipe altyapısı yardımıyla poz tahmini değerleri elde edilmiştir. V_{eller} veri seti için MediaPipe Holistic (Hands) yaklaşımından, $V_{eller-vücut}$ veri seti için MediaPipe Holistic (Hands) ve MediaPipe Holistic (Pose) yaklaşımlarından yararlanılmıştır. Farklı derin öğrenme modellerinin eğitim ve test süreçlerinin aynı veri setleri üzerinde gerçekleştirilebilmesi için her bir zaman adımı için elde edilen kilit noktaları değerleri verilerin toplanması ve düzenlenmesi aşamasında açılmış olan, videonun ait olduğu ürün klasörünün içerisindeki ilgili montaj eylemi klasörüne Numpy dizisi (.npy) dosyası formatında kaydedilmiştir. Her bir eylem klasörü içerisinde videonun sahip olduğu çerçeve sayısı kadar .npy dosyası bulunmaktadır. Bu aşamadan sonraki işlemler V_{eller} ve $V_{eller-vücut}$ veri setleri için ayrı ayrı uygulanmıştır.

5.3.3. Verilerin hazırlanması

Modellerin derin öğrenmeye dayalı sınıflandırma algoritmaları ile eğitilmesi ve test edilmesi amacıyla gerçekleştirilen verilerin hazırlanması aşamasında montaj hattından elde edilen veri setlerine sırası ile verilerin etiketlenmesi, veri setinin ayrılması, veri arttırma, segmentasyon ve kategorik değişken dönüşümü adımları uygulanmıştır.

5.3.3.1. Verilerin etiketlenmesi

Bu adımda .npy dosyası formatında klasörlere kaydedilen zaman adımlarının nitelik değerlerini (V_{eller} için 126 nitelik, $V_{eller-vücut}$ için 258 nitelik) taşıyan satırlar Numpy (1.18.5 sürüm) kütüphanesi yardımıyla Python kod bloğu ile Spyder geliştirme ortamına alınmıştır. İlgili satırın etiketi, dosyanın bulunduğu eylem klasörünün ismi kullanılarak oluşturulmuştur. Bu şekilde toplam 40054 örneğe sahip iki zaman serisi veri seti elde edilmiştir. Montaj eylemi türüne göre örnek sayıları Şekil 5.3'te verilmektedir.



Şekil 5.3. Montaj hattı veri setlerinde montaj eylemi sınıfına göre örnek sayıları.

5.3.3.2. Veri setinin ayrılması


Çalışmanın bu aşamasında, veri seti derin öğrenmeye dayalı sınıflandırma modellerinin eğitilmesi için %80 oranında eğitim veri seti ve eğitilen modellerin test edilmesi için %20 oranında test veri seti olmak üzere ikiye ayrılmıştır. Veri toplama aşamasında elde edilen 40 videodan 32 videoya ait poz ve etiket verileri eğitim veri seti için, 8 videoya ait veriler ise test veri seti için kullanılacaktır. Veri setinin ayrılması işlemi V_{eller} ve $V_{eller-vücut}$ veri setlerinin her ikisi için de ayrı ayrı uygulanmıştır. V_{eller} ve $V_{eller-vücut}$ veri setlerinin ayrılması ile 31781 zaman adımı verilerinden oluşan V_{eller}^E ve $V_{eller-vücut}^E$ veri setleri ve 8273 adet örnekten oluşan V_{eller}^T ve $V_{eller-vücut}^T$ test veri setleri elde edilmiştir.

5.3.3.3. Veri artırma


Bu aşama modelin çevrimiçi olarak 15 fps hızında çalışması ve geliştirilecek olan derin öğrenmeye dayalı aktivite tanıma modelinin performansının iyileştirilmesi için verilerin ayrılması ile elde edilen eğitim veri setlerine veri artırma işleminin uygulanmasıdır. Çalışmada önerilen aşağı örnekleme ve ölçekleme işlemlerini içeren iki aşamalı veri artırma yaklaşımı V_{eller}^E ve $V_{eller-vücut}^E$ eğitim veri setlerinin her ikisi için de ayrı ayrı uygulanır. Burada ölçekleyicinin belirlendiği Gauss dağılımının standart sapması deneysel olarak belirlenmiş ve 0,1 değeri kullanılmıştır. V_{eller}^T ve $V_{eller-vücut}^T$ test veri setlerine ise aşağı örnekleme işlemi uygulanarak örnekleme oranı 15 fps olacak şekilde düzenlenmiştir.

5.3.3.4. Segmentasyon

Veri arttırma işleminden sonraki adım elde edilen eğitim ve test verilerinin bölümlere ayrılmasıdır. Bu çalışmada veri segmentasyonu işlemi, eşit zaman adımlı kayan pencere tekniği (sliding window) kullanılarak gerçekleştirilmiştir. Bu segmentler, daha sonra montaj eylemi tanıma için derin öğrenme modellerini eğitmek ve test etmek için kullanılacaktır. Modellerin bir montaj eyleminden diğer montaj eylemine geçişi algılayabilme yeteneklerini geliştirmek için ardışık pencereler üst üste bindirilmiştir. Veri seti parçaları tüm veri setinden 2 saniyelik zaman serisi verilerini kapsayabilen bir kayan pencere kullanılarak bölümlere ayrılmıştır. Yani pencere büyüklüğü (window size) 30 olarak seçilmiştir. Çünkü video kaydı 30 fps hızında gerçekleştirilmiştir ve veriler veri arttırma aşamasında bir zaman adımı atlayacak şekilde düzenlenmiştir. Literatürdeki insan aktivite tanıma çalışmalarında segmentasyon aşamasında, %50 (Preece ve ark, 2008; Issa ve ark, 2022), %75 (Tao ve ark, 2018), %80 (Aziz ve ark, 2022; Attal ve ark, 2015; Han ve ark, 2021), %80,5 (Reiss ve Stricker, 2012), %93,33 (Odhiambo ve ark, 2022) gibi çeşitli örtüşme oranları kullanılmıştır. Bu çalışmada, herhangi iki ardışık veri seti parçasının %83,3 örtüşmesi (overlapping) bulunmaktadır. Dolayısıyla kayma adımı 5'tir. Pencere büyüklüğü ve örtüşme oranı değerleri deneysel olarak belirlenmiştir. Örneklerde boş zaman adımlarının doldurulması için Keras kütüphanesinin `pad_sequences()` fonksiyonu kullanılarak dolgu işlemi uygulanmış ve girdi verileri maksimum uzunluğa (pencere uzunluğu) kadar doldurulmuştur. Dolgu tipi 'post-padding' olarak seçilmiştir. Post-padding işleminde girdi dizileri seçilen maksimum uzunluğa kadar belirlenen değerler ile son kısımda doldurulur. Dolgu değeri, her biri -999 değerine sahip girdi niteliği sayısı uzunluğunda bir dizi olarak belirlenmiştir. Bu uzunluk V_{eller} veri setinde 126 iken $V_{eller-vücut}$ veri setinde 258'dir. Bu şekilde eğitim veri setinde 12707, test veri setinde 822 adet veri seti parçası (örnek) oluşturularak son çerçevedeki sınıf ile etiketlenmiştir. Burada bir aktivite için bir örnek, zaman serisi verilerinin bir penceresidir. Her pencerede 30 zaman adımı vardır ve V_{eller} veri setinde her zaman adımı 126 niteliğe sahipken $V_{eller-vücut}$ veri setinde 258 girdi değişkeni bulunmaktadır. Oluşturulan eğitim ve test veri kümeleri (V_{eller} ve $V_{eller-vücut}$) için montaj eylemi türüne göre örnek sayıları sırasıyla Şekil 5.4 ve Şekil 5.5'te verilmektedir.



Şekil 5.4. Segmentasyon işlemi sonrası montaj hattı eğitim veri setinde montaj eylemi sınıfına göre örnek sayıları.



Şekil 5.5. Segmentasyon işlemi sonrası montaj hattı test veri setinde montaj eylemi sınıfına göre örnek sayıları.

5.3.3.5. Kategorik değişken dönüşümü

Eğitim ve test veri setlerinin girdi nitelikleri incelendiğinde, tüm nitelik değerlerinin sürekli değerlere sahip olduğu, çıktı değişkeninin ise montaj eylemi sınıflarını barındırdığından kategorik değişken olduğu anlaşılmaktadır. Bu çalışmada etiket diğer bir deyişle çıktı değişkeninin kategorik değişken dönüşümü Keras kütüphanesinin `to_categorical` fonksiyonu ile gerçekleştirilmiştir. Bu fonksiyon ile bir sınıf vektörü formatında olan eğitim ve test veri seti etiket değişkenleri ikili değerlere ve kategori sayısı (montaj eylemi sınıfı sayısı olan 15) kadar sütunlara sahip ikili sınıf matrisleri haline getirilmiştir.

5.3.4. Derin öğrenmeye dayalı sınıflandırma modellerinin geliştirilmesi

Bu çalışmada, oluşturulan iki veri seti (V_{eller} ve $V_{eller-vücut}$) üzerinde CNN, LSTM, GRU, BiLSTM ve BiGRU modelleri ve bu modellerin hibrit kullanımları ile montaj eylemi sınıflandırma modelleri geliştirilerek performansları karşılaştırılmaktadır. Modeller veri artırma işlemi uygulanmamış 15 fps örnekleme oranındaki orijinal veri setleri (OV) ve veri artırma işlemi gerçekleştirilmiş veri setleri (AV) üzerinde ayrı ayrı eğitilmiştir. Eğitim ve test veri setlerinin boyutları Tablo 5.3'te verilmektedir.

Tablo 5.3. Eğitim ve test veri setlerinin boyutları.

Veri Seti	Veri Seti Bölümü	Boyutu	Veri Seti	Veri Seti Bölümü	Boyutu	
V_{eller}	OV	V_{eller}^{GE}	(3173, 30, 126)	OV	V_{eller}^{GE}	(3173, 30, 258)
		V_{eller}^{GT}	(822, 30, 126)		V_{eller}^{GT}	(822, 30, 258)
		V_{eller}^{CE}	(3173, 15)		V_{eller}^{CE}	(3173, 15)
	AV	V_{eller}^{CT}	(822, 15)	AV	V_{eller}^{CT}	(822, 15)
		V_{eller}^{GE}	(12707, 30, 126)		V_{eller}^{GE}	(12707, 30, 258)
		V_{eller}^{GT}	(822, 30, 126)		V_{eller}^{GT}	(822, 30, 258)
$V_{eller-vücut}$	AV	V_{eller}^{CE}	(12707, 15)	AV	V_{eller}^{CE}	(12707, 15)
		V_{eller}^{CT}	(822, 15)		V_{eller}^{CT}	(822, 15)

Montaj eylemi tanıma için derin öğrenme modellerinin eğitimi sırasında python (Python 3.8 sürümü) programlama dili ile Anaconda platformu üzerindeki Spyder editöründe Tensorflow (2.3.0 sürüm) kütüphanesinin arka ucuna sahip Keras kütüphanesi kullanılarak derin öğrenme modelleri oluşturulmuştur. Bu modeller CNN, LSTM, GRU, Bi-LSTM, Bi-GRU, CNN-LSTM, CNN-GRU, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN modelleridir. Modellerde maskeleyme katmanındaki maske değeri, dolgu değeri olan her biri -999 değerine sahip girdi niteliği sayısı uzunluğunda bir diziye eşitlenmiştir. Modellerin eğitimi birinci dereceden gradyanı temel alan stokastik bir optimizasyon algoritması olan Adam optimizasyon algoritması

(Kingma ve Ba, 2014) kullanılarak gerçekleştirilmiştir. Adam optimizasyon algoritması, minimum bellek kullanımıyla hızlı ve verimli performansı ile tanınmaktadır (Athota ve Sumathi, 2022). Her bir modelin eğitiminde, uyum yeteneğini geliştirmek için 0,0001 olan küçük bir öğrenme oranı (learning rate) seçilmiştir. Maliyet fonksiyonu olarak da bilinen kayıp fonksiyonu, bir sinir ağını veya diğer makine öğrenmesi modellerini eğitmek için kullanılır (Tian ve ark, 2022). Çok sınıflı sınıflandırma uygulaması olduğu için, eğitim aşamasında tahmin edilen ve gerçek değerler arasındaki hatayı ölçmek için kayıp fonksiyonu olarak kategorik çapraz-entropi (categorical cross-entropy) kullanılmıştır. Modeller eğitilirken eğitim turu (epoch) sayısı 5000, yığın (batch) büyüklüğü ise 32 olarak belirlenmiştir. Modeller daha sonra gerçek zamanlı uygulamada kullanılabilir üzere kaydedilmiştir.

5.3.5. Montaj eylemlerinin tanınması modellerinin performanslarının değerlendirilmesi


Çalışmada geliştirilen derin öğrenmeye dayalı 10 sınıflandırıcı modelin etkinlikleri yapılan deneylerin sonuçları göz önünde bulundurularak 3 bölümde incelenmektedir: veri arttırma yaklaşımının etkisinin değerlendirilmesi, poz tahmini yaklaşımlarının karşılaştırılması ve derin öğrenme modellerinin performanslarının karşılaştırılması. Doğruluk skoru, duyarlılık, kesinlik, F1-Skor performans ölçütlerinin elde edilmesi için Scikit-learn (1.1.1 sürüm) kütüphanesi kullanılmıştır. Karmaşıklık matrisi grafiği için ise Seaborn (0.11.2. sürüm) kütüphanesinden faydalanılmıştır.

5.3.5.1. Veri arttırma yaklaşımının etkisinin değerlendirilmesi


Bu bölümde veri arttırma yaklaşımının her bir derin öğrenme modeli için etkisi analiz edilmektedir. İki poz tahmini yaklaşımı ile elde edilen (V_{eller} ve $V_{eller-vücut}$) ve veri arttırma yaklaşımının uygulanmadığı (a) ve veri arttırma yaklaşımının uygulandığı (b) veri setleri üzerinde eğitilen her bir modele ait karmaşıklık matrisleri EK B.1-B.20'de verilmektedir.

Şekil 5.6'da derin öğrenmeye dayalı montaj eylemi tanıma modellerinin veri arttırma yaklaşımına göre doğruluk performans ölçütü bazında karşılaştırmalı deneysel sonuçları verilmektedir. Şekil 5.6(a)'da sadece ellerdeki kilit noktaların poz tahmini değerlerinin (V_{eller}) kullanılması ile elde edilen sonuçlar, Şekil 5.6(b)'de ise ellerdeki kilit noktaların ve vücuttaki kilit noktaların poz tahminlerinin birleştirilmesi ile elde

edilen poz tahmin değerlerinin ($V_{\text{eller-vücut}}$) kullanılması ile elde edilen sonuçlar gösterilmektedir. V_{eller} veri seti üzerinde gerçekleştirilen deneylerin sonuçları incelendiğinde, veri arttırma yaklaşımının kullanılması ile tüm modellerin doğruluk puanlarında artış olduğu görülmektedir. Bu puan artışı, %0,9732 ile %4,5012 arasında değişmektedir. En yüksek artış LSTM modelinde gerçekleşmiştir. $V_{\text{eller-vücut}}$ veri seti üzerinde gerçekleştirilen deneylerin sonuçlarına bakıldığında, benzer şekilde on sınıflandırma modelinde de veri arttırma yaklaşımı kullanımının doğruluk değerlerini arttırdığı anlaşılmaktadır. En düşük artış %0,7299 ile BiGRU modelinde, en yüksek artış %7,7859 ile CNN-LSTM modelinde gerçekleşmiştir.



(a) V_{eller} veri seti




(b) $V_{\text{eller-vücut}}$ veri seti


Şekil 5.6. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre doğruluk performans ölçütü bazında karşılaştırılması.

Şekil 5.7’de geliştirilen sınıflandırma modellerinin veri arttırma yaklaşımına göre kesinlik performans ölçütü bazında karşılaştırmalı deneysel sonuçları sunulmaktadır. Şekil 5.7(a)’da V_{eller} veri seti üzerinde geliştirilen modellerin sonuçları incelendiğinde, veri arttırma yaklaşımının tüm modellerde kesinlik puanını arttırdığı, bu artışın

%0,3473 ile %4,5029 arasında deđiřtiđi anlařılıbilir. Őekil 5.7(b)'de verilen $V_{eller-vucut}$ veri seti üzerindeki sonuçlar analiz edildiđinde, benzer Őekilde tüm modellerin kesinlik deđerinin yükseldiđi görülmektedir. Bu yükseliř özellikle CNN-LSTM modelinde %9,4417'ye ulařmıřtır.



(a) V_{eller} veri seti




(b) $V_{eller-vucut}$ veri seti


Őekil 5.7. Modellerin veri arttırma yaklařımı uygulanma durumuna göre kesinlik performans ölçütü bazında karřılařtırılması.

Derin öğrenmeye dayalı modellerin veri arttırma yaklařımına göre duyarlılık performans ölçütü bazında karřılařtırılması Őekil 5.8'de gösterilmektedir. V_{eller} veri seti üzerinde gerçeđleştirilen deney sonuçlarını gösteren Őekil 5.8(a)'ya göre ve $V_{eller-vucut}$ veri seti üzerinde gerçeđleştirilen deney sonuçlarını gösteren Őekil 5.8(b)'ya göre veri arttırma yaklařımı tüm modellerin duyarlılık deđerleri açısından performansını

olumlu yönde değiřtirmiřtir. V_{eller} veri seti üzerinde en düşük iyileřtirme %1,4273 puan artışı ile BiLSTM modelinde, en yüksek iyileřtirme %4,9283 puan artışı ile CNN-LSTM modelinde gerçekleřmiřtir. $V_{eller-vücut}$ veri seti üzerinde ise en düşük iyileřtirme %0,9833 puan artışı ile BiGRU modelinde, en yüksek artış %8,958 puan artışı ile CNN-LSTM modelinde gerçekleřmiřtir.



(a) V_{eller} veriseti




(b) $V_{eller-vücut}$ veriseti


Şekil 5.8. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre duyarlılık performans ölçütü bazında karşılaştırılması.

Şekil 5.9 on montaj eylemi tanıma modelinin veri arttırma yaklaşımına göre F1-Skor performans ölçütü bazında karşılaştırılmasını göstermektedir. V_{eller} veri seti üzerinde gerçeleştirilen deneylerin sonuçları (Şekil 5.9(a)) ve $V_{eller-vücut}$ veri seti üzerinde gerçeleştirilen deneylerin sonuçları (Şekil 5.9(b)), tüm modellerin F1-Skor değerlerinin veri arttırma yaklaşımı ile arttığını göstermektedir. V_{eller} veri seti üzerinde

en düşük artış %86,0999'dan %87,1331'e artış ile GRU modelinde, en yüksek artış %79,5968'den %84,3812'ye yükseliş ile LSTM modelinde gerçekleşmiştir. $V_{eller-vücut}$ veri seti üzerinde ise en düşük artış %91,1533'ten %92,1626'ya artış ile BiGRU modelinde, en yüksek artış %80,6263'dan %89,7573'e yükseliş ile CNN-LSTM modelinde gerçekleşmiştir.



(a) V_{eller} veriseti




(b) $V_{eller-vücut}$ veriseti

Şekil 5.9. Modellerin veri artırma yaklaşımı uygulanma durumuna göre F1-Skor performans ölçütü bazında karşılaştırılması.


5.3.5.2. Poz tahmini yaklaşımlarının karşılaştırılması

Çalışma kapsamında montaj eylemlerinin tanınması amacıyla geliştirilen derin öğrenme modellerinin poz tahmini yaklaşımlarına göre doğruluk ölçütü değerlerinin karşılaştırılması Şekil 5.10'da verilmektedir. Şekil 5.10(a) veri artırma yaklaşımı uygulanmayan veri setleri üzerinde eğitilmiş modellerin doğruluk değerlerini, Şekil

5.10(b) veri arttırma yaklaşımı uygulanmış veri setleri üzerinde eğitilmiş modellerin doğruluk değerlerini yansıtmaktadır. Grafikler incelendiğinde, veri arttırma yaklaşımı uygulanmadığında (Şekil 5.10(a)), CNN-LSTM modeli hariç tüm modellerin MediaPipe (Hands) ve MediaPipe (Pose) poz tahminlerinin birleştirilmesi ile elde edilen poz değerleri üzerinde eğitildiğinde ($V_{eller-vücut}$) daha iyi ortalama doğruluk değeri elde ettikleri görülmektedir. İki veri seti (V_{eller} ve $V_{eller-vücut}$) ile ayrı ayrı gerçekleştirilen deneylerin model bazında ortalama doğruluk değerleri arasındaki farkın CNN, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN modelinde 5 puana yakın veya üzerinde olduğu anlaşılmaktadır. CNN-LSTM modeli sadece MediaPipe (Hands) poz tahmini ile elde edilen poz değerleri üzerinde eğitildiğinde (V_{eller}) doğruluk değeri açısından daha iyi performans göstermiştir. Veri arttırma yaklaşımı uygulandığında (Şekil 5.10(b)) ise, LSTM modeli hariç tüm modeller MediaPipe (Hands) ve MediaPipe (Pose) poz tahminlerinin birleştirilmesi ile elde edilen poz değerleri üzerinde eğitildiğinde daha iyi doğruluk değeri elde etmişlerdir.




(a) Veri artırma yaklaşımı uygulanmayan




(b) Veri artırma yaklaşımı uygulanan

Şekil 5.10. Modellerin poz tahmini yaklaşımlarına göre doğruluk performans ölçütü bazında karşılaştırılması.

Çalışmada geliştirilen derin öğrenme modellerinin poz tahmini yaklaşımlarına göre kesinlik ölçütü karşılaştırmalı değerleri Şekil 5.11’de verilmektedir. Veri artırma yaklaşımı uygulanmadığı durumda (Şekil 5.11(a)), CNN-LSTM modeli hariç tüm modeller sadece ellerdeki kilit noktaların poz değerlerini kullanmak yerine hem ellerdeki hem de vücuttaki kilit noktaların poz değerleri kullanıldığında kesinlik ölçütü bakımından daha iyi sınıflandırma gücüne sahiptir. İki yaklaşım (V_{eller} ve $V_{eller-vücut}$) arasındaki kesinlik değerlerine göre fark 0,3617 ile 7,0943 arasında değişmektedir. Şekil 5.11(b)’de verilen veri artırma yaklaşımının uygulandığı deneylerin ortalama kesinlik değerleri sonuçları incelendiğinde, sadece LSTM modeli V_{eller} veri seti üzerinde daha yüksek kesinlik değerine sahipken, diğer modeller $V_{eller-vücut}$ veri seti üzerinde kesinlik ölçütü değeri açısından daha iyi performans göstermiştir.




(a) Veri artırma yaklaşımı uygulanmayan




(b) Veri artırma yaklaşımı uygulanan

Şekil 5.11. Modellerin poz tahmini yaklaşımlarına göre kesinlik performans ölçütü bazında karşılaştırılması.

Derin öğrenme modellerinin poz tahmini yaklaşımlarına göre duyarlılık ölçütü değerlerinin karşılaştırılması Şekil 5.12’de gösterilmektedir. Veri artırma yaklaşımı uygulanmayan deneylerin duyarlılık değerlerini gösteren Şekil 5.12(a) incelendiğinde, CNN-LSTM dışındaki tüm modellerin $V_{\text{eller-vücut}}$ veri seti üzerinde daha iyi performans gösterdiği, veri artırma yaklaşımı uygulanan deneylerin duyarlılık değerlerini gösteren Şekil 5.12(b) incelendiğinde ise LSTM dışındaki tüm modellerin $V_{\text{eller-vücut}}$ veri seti üzerinde daha iyi duyarlılık değerleri elde ettiği görülmektedir.




(a) Veri artırma yaklaşımı uygulanmayan




(b) Veri artırma yaklaşımı uygulanan

Şekil 5.12. Modellerin poz tahmini yaklaşımlarına göre duyarlılık performans ölçütü bazında karşılaştırılması.

Montaj eylemi tanıma modellerinin poz tahmini yaklaşımlarına göre F1-Skor ölçütü değerlerinin karşılaştırılması Şekil 5.13'te sunulmaktadır. F1-Skor değerleri incelendiğinde, diğer performans ölçütlerinde olduğu gibi veri artırma yaklaşımı uygulanmadığında (Şekil 5.13(a)) sadece CNN-LSTM modeli V_{eller} veri seti üzerinde daha iyi F1-Skor değeri sağlamış, veri artırma yaklaşımı uygulandığında (Şekil 5.13(b)) ise sadece LSTM modeli V_{eller} veri seti üzerinde daha iyi F1-Skor değeri vermiştir. Diğer tüm modeller $V_{eller-vücut}$ veri setinde daha iyi performans göstermiştir.



(a) Veri arttırma yaklaşımı uygulanmayan



(b) Veri arttırma yaklaşımı uygulanan

Şekil 5.13. Modellerin poz tahmini yaklaşımlarına göre F1-Skor performans ölçütü bazında karşılaştırılması.

5.3.5.3. Derin öğrenme modellerinin performanslarının karşılaştırılması

Tablo 5.4'te V_{eller} veri seti üzerinde veri arttırma yaklaşımı uygulanmadan eğitilen derin öğrenmeye dayalı 10 sınıflandırıcı modelin kayıp, doğruluk, kesinlik ve F1-Skor değerleri verilmektedir. 0,6790 değeri ile en düşük kayıp değerine CNN modeli sahipken en yüksek kayıp değeri 1,41184 değeri ile BiLSTM modelinden elde edilmiştir. En düşük doğruluk, kesinlik, duyarlılık ve F1-Skor değerlerine sahip model LSTM modelidir. Bu değerler sırasıyla %82,8467, %80,2849, %79,5061 ve %79,5968'dir. CNN modelinin LSTM, GRU, BiLSTM ve BiGRU modelleri ile hibrit kullanımı sayesinde bu dört modelin tekli kullanımlarından daha iyi doğruluk değeri elde edilmiştir. CNN-BiGRU modeli ile CNN-BiGRU-CNN modeli aynı %90,5109

değeri ile aynı doğruluk sonucuna ulaşmasına rağmen farklı kesinlik, duyarlılık ve F1-Skor değerlerine sahiplerdir. CNN-BiGRU-CNN modeli sırasıyla %88,5395 ve %88,5205 değeri ile biraz daha yüksek kesinlik ve F1-Skor değerleri sağlamışken, CNN-BiGRU'nun duyarlılık değeri %77,9918 ile CNN-BiGRU-CNN modelinden biraz daha yüksektir.

Tablo 5.4. V_{eller} veri seti üzerinde veri arttırma yaklaşımı uygulanmadan eğitilen modellerin performansı.

Model	Kayıp	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-Skor (%)
CNN	0,6790	86,3747	83,5311	83,7631	83,5510
LSTM	1,3739	82,8467	80,2849	79,5061	79,5968
GRU	0,8368	88,3212	86,6757	85,8042	86,0999
BiLSTM	1,4184	87,4696	84,7324	85,4918	84,6750
BiGRU	1,3030	87,4696	86,1192	85,4958	85,6110
CNN-LSTM	1,1852	85,5231	83,0106	81,8227	81,9182
CNN-GRU	0,7669	90,2676	87,9691	88,3086	88,0458
CNN-BiLSTM	1,0163	89,1728	86,7522	86,9098	86,4952
CNN-BiGRU	0,7839	90,5109	88,2902	88,9918	88,4414
CNN-BiGRU-CNN	0,7723	90,5109	88,5395	88,9507	88,5205

Tablo 5.5'te V_{eller} veri seti üzerinde veri arttırma yaklaşımı uygulanarak eğitilen modellerin performans ölçütü sonuçları gösterilmektedir. 0,4659 değeri ile CNN modeli en düşük kayıp değerine, 1,0256 değeri ile BiLSTM en yüksek kayıp değerine sahiptir. LSTM modeli sırasıyla %87,3470, %84,7878, %84,3528 ve %84,3812 değerleri ile en düşük doğruluk, kesinlik, duyarlılık ve F1-Skor değerleri sağlamıştır. CNN ve BiLSTM modeli LSTM modelinden, CNN ve BiGRU modelleri de GRU modelinden doğruluk, kesinlik, duyarlılık ve F1-Skor ölçütleri açısından daha iyi performans göstermiştir. CNN modelinin LSTM, GRU, BiLSTM ve BiGRU modelleri ile hibrit kullanımı sayesinde, LSTM, GRU, BiLSTM ve BiGRU modellerinin tekli kullanımlarından daha yüksek doğruluk, kesinlik, duyarlılık ve F1-Skor değerleri elde edilmiştir. Modellerin ikili hibrit kullanımlarında sırası ile %92,3358, %90,7798 ve %90,3695 değerleri ile en yüksek doğruluk, duyarlılık ve F1-Skor değerlerini sağlayan model CNN-BiGRU iken, en yüksek kesinlik değerini %90,8037 değeri ile BiLSTM modeli sağlamıştır. 10 sınıflandırıcı model içerisinde doğruluk, kesinlik, duyarlılık ve

F1-Skor deęerleri aısından en yksek deęerler CNN-BiGRU-CNN modeline aittir. Bu deęerler sırasıyla, %92,4574, %90,8932, %90,8434 ve %90,6982'dir.

Tablo 5.5. V_{eller} veri seti zerinde veri arttırma yaklaşımlı uygulanarak eęitilen modellerin performansı.

Model	Kayıp	Doęruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-Skor (%)
CNN	0,4659	89,1727	87,3447	87,2493	87,2182
LSTM	0,8540	87,3479	84,7878	84,3528	84,3812
GRU	0,7244	89,2944	87,0230	87,6488	87,1331
BiLSTM	1,0256	89,4161	87,5223	86,9191	89,4161
BiGRU	0,7191	90,6326	89,6546	88,7621	89,0809
CNN-LSTM	0,7632	89,4161	86,9748	86,7510	86,6580
CNN-GRU	0,6057	91,7275	89,4406	89,8840	89,6003
CNN-BiLSTM	0,7335	92,2141	90,8037	89,9389	90,2206
CNN-BiGRU	0,6959	92,3358	90,2540	90,7798	90,3695
CNN-BiGRU-CNN	0,6938	92,4574	90,8932	90,8434	90,6982

Tablo 5.6 $V_{eller-vucut}$ veri seti zerinde veri arttırma yaklaşımlı uygulanmadan gerekleřtirilen derin ęrenme modellerinin karřılařtırmalı deneysel sonularını sunmaktadır. En dřk kayıp deęeri 0,3374 deęeri ile CNN-BiGRU-CNN modelindedir. En yksek kayıp deęeri ise 1,7598 deęeri ile LSTM modeline aittir. Aynı zamanda %80,6465, %80,0535 deęerleri ile en dřk duyarlılık ve F1-Skor puanlarını da yine LSTM modeli vermiřtir. LSTM ve CNN-LSTM modelleri %84,3066 deęeri ile en dřk doęruluk sonucu vermiřtir. BiLSTM modeli beř performans lt iin LSTM modelinden, BiGRU modeli ise kayıp deęeri hari dięer drt performans lt iin GRU modelinden daha iyi puanlar saęlamıřtır. Doęruluk, kesinlik ve F1-Skor performans ltleri iin en yksek performansı CNN-BiGRU modeli saęlamıřtır.

Tablo 5.6. $V_{\text{eller-vücut}}$ veri seti üzerinde veri arttırma yaklaşımı uygulanmadan eğitilen modellerin performansı.

Model	Kayıp	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-Skor (%)
CNN	0,4281	91,9708	89,2711	90,1927	89,5069
LSTM	1,7598	84,3066	80,6466	80,6465	80,0535
GRU	0,7652	92,2141	90,2603	90,0971	89,7978
BiLSTM	1,1135	91,1192	88,3653	89,4160	88,4898
BiGRU	0,8190	93,4307	91,3272	91,7310	91,1533
CNN-LSTM	1,2579	84,3066	80,5870	81,1183	80,6263
CNN-GRU	0,3376	93,9173	91,9299	91,8343	91,6376
CNN-BiLSTM	0,5053	94,8905	93,7172	93,5240	93,2970
CNN-BiGRU	0,3552	95,6204	95,3845	93,8119	94,3207
CNN-BiGRU-CNN	0,3374	95,4988	94,3652	94,2146	94,0830

Tablo 5.7’de $V_{\text{eller-vücut}}$ veri seti üzerinde veri arttırma yaklaşımı uygulanarak gerçekleştirilen derin öğrenme modellerinin karşılaştırmalı deneysel sonuçları verilmektedir. En iyi kayıp değeri CNN-GRU modeli ile elde edilmiştir. Beş performans ölçütüne göre en kötü performans LSTM modeli ile elde edilmiştir. LSTM, GRU, BiLSTM ve BiGRU modellerinin CNN modeli ile birleştirilmesi beş performans ölçütünde de oldukça yüksek iyileştirmeler meydana getirmiştir. Özellikle CNN-BiGRU modelinde BiGRU modeline göre %4,3796 doğruluk puanı artışı olmuştur. CNN-BiGRU-CNN modeli doğruluk, kesinlik, duyarlılık ve F1-Skor olmak üzere dört performans ölçütünde de sırasıyla %97,3236, %96,6805, %96,6718 ve %96,5519 olacak şekilde en yüksek değerleri vermiştir.

Tablo 5.7. $V_{eller-vücut}$ veri seti üzerinde veri arttırma yaklaşımı uygulanarak eğitilen modellerin performansı.

Model	Kayıp	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-Skor (%)
CNN	0,2487	95,1338	93,5697	94,0489	93,6362
LSTM	1,3185	86,0097	82,6899	83,5175	82,2423
GRU	0,4590	94,7689	93,2575	93,8277	93,3178
BiLSTM	1,0792	92,4574	91,2935	90,9985	90,8355
BiGRU	0,5634	94,1606	92,0153	92,7143	92,1626
CNN-LSTM	0,6701	92,0925	90,0287	90,0763	89,7573
CNN-GRU	0,1831	97,2019	96,3798	96,5522	96,3968
CNN-BiLSTM	0,2664	96,8370	96,0403	96,0352	95,8025
CNN-BiGRU	0,2327	97,2019	96,6748	96,5008	96,4135
CNN-BiGRU-CNN	0,1961	97,3236	96,6805	96,6718	96,5519

5.4. Seru Üretim Sisteminde Uygulama

Bu bölümde, çalışmada önerilen metodolojinin montaj hattı sistemi uygulamasında üzerinde çalışılan ürün için seru üretim sisteminde uygulanması ve etkinliğinin değerlendirilmesi anlatılmaktadır. Bu amaçla firmada, Şekil 5.14'te gösterildiği gibi seru üretim sistemi çeşitlerinden yatai kurulmuştur. Yataide tek bir çalışan ürünün tüm montaj işlemlerini baştan sona sırasıyla gerçekleştirmektedir. Montaj süreci boyunca kullanılması gereken tüm montaj bileşenleri ve montaj araçları çalışanın önünde çalışma tezgahında eksiksiz bir şekilde bulunmaktadır.




Şekil 5.14. Uygulama için firmada kurulan yatai yerleşimi.

5.4.1. Verilerin toplanması ve düzenlenmesi

Seru üretim sistemi montaj eylemi veri setinin oluşturulması amacıyla, yataide 40 adet ürün için bir çalışan tarafından ardı ardına gerçekleştirilen 15 montaj işleminin video

görüntüleri, çalışanın karşısında çalışanın tüm faaliyetlerini ve montaj sürecindeki tüm bileşenleri kapsayabilecek şekilde yerleştirilen kamera ile sistem gereksinimleri bölümünde detayları verilen donanım ve montaj hattı uygulamasında bilgileri sunulan python kod bloğu sayesinde toplanarak 1920 x 1080 piksel çözünürlükte 30 fps hızı ile tek bir video halinde bilgisayara kaydedilmiştir. Kaydedilen video görüntüsü, 40 ürün ve 15 montaj eylemi için Windows Fotoğraflar uygulaması aracılığıyla kırılarak 1280 x 720 piksel çözünürlükte kaydedilmiştir. Bu şekilde 600 adet yeni video elde edilmiştir. Videoların saklanması için oluşturulan klasör SERU_Video olarak isimlendirilmiştir. Montaj Hattı sisteminde bahsedildiği gibi bu klasör içerisine videolar ve poz verileri için gerekli olacak boş klasörler yerleştirilmiştir.

Seru üretim sisteminde gerçekleştirilen farklı sürelerle sahip montaj eylemlerinin ortalama çerçeve sayıları Şekil 5.15'te verilmektedir. Şekilde görüldüğü gibi, ortalama olarak, ME₅ işlemi en uzun sürede tamamlanmaktadır. En kısa sürede tamamlanan işlem ise ME₁ işlemidir.



Şekil 5.15. Seru üretim sistemi görüntü veri setindeki her bir montaj eylemi için ortalama çerçeve sayıları.


5.4.2. Poz tahmini

Seru Üretim sistemi için elde edilen video görüntüleri üzerinde MediaPipe holistic (hands) modeli uygulanarak V_{eller} veri seti için, MediaPipe holistic (hands) modeli ve MediaPipe holistic (pose) modeli uygulanarak $V_{eller-vücut}$ veri seti için poz verileri elde edilmiştir. Montaj hattı uygulamasında olduğu gibi 0,5 minimum algılama güven

değeri ve 0,5 minimum izleme güven değeri kullanılmıştır. Elde edilen kilit noktaları değerleri bir önceki aşamada açılmış olan boş klasörlere Numpy dizisi (.npy) dosyası formatında kaydedilmiştir.

5.4.3. Verilerin hazırlanması

Bu aşamada, poz tahmini aşamasında kaydedilen V_{eller} veri seti ve $V_{eller-vücut}$ veri setindeki zaman adımlarına ait poz değerlerine sahip örnekler Spyder geliştirme ortamına alınarak buldukları eylem klasörünün ismi kullanılarak etiketlendirilmiştir. Elde edilen her bir veri setinde 62927'şer örnek bulunmaktadır. Seru üretim sistemi veri setlerinde montaj eylemi türüne göre örnek sayıları Şekil 5.16'da gösterilmektedir.




Şekil 5.16. Seru üretim sistemi veri setlerinde montaj eylemi sınıfına göre örnek sayıları.


V_{eller} ve $V_{eller-vücut}$ veri setleri %80 eğitim %20 test veri seti (32 video eğitim, 8 video ise test veri seti) olacak şekilde ikiye ayrılmıştır. Elde edilen V_{eller}^E ve $V_{eller-vücut}^E$ eğitim veri setleri 50454 zaman adımı verilerinden oluşmaktadır. V_{eller}^T ve $V_{eller-vücut}^T$ test veri setleri ise 12473 adet örnekten oluşmaktadır.

Çalışmada önerilen iki aşamalı veri artırma yaklaşımı eğitim veri setleri için uygulanmıştır. Montaj hattı uygulamasında olduğu gibi ölçekleyicinin belirlendiği Gauss dağılımının standart sapması için 0,1 değeri kullanılmıştır. Diğer taraftan test veri setlerine örnekleme oranı 15 fps olması için aşağı örnekleme işlemi uygulanmıştır.

Veri segmentasyonu işlemi örtüşen kayan pencereler yaklaşımı kullanılarak pencere büyüklüğü 30, örtüşme oranı %83,33 olacak şekilde eğitim ve test veri setlerine uygulanmıştır. Aynı zamanda montaj hattı uygulamasında olduğu gibi örneklerdeki boş zaman adımlarının doldurulması amacıyla dolgu işlemi gerçekleştirilmiştir. İşlemler sonucu eğitim veri setlerinde 12707, test veri setlerinde 822 adet veri seti parçası (örnek) oluşturulmuştur. Oluşturulan eğitim ve test veri setleri için montaj eylemi türüne göre örnek sayıları sırasıyla Şekil 5.17 ve Şekil 5.18’de verilmektedir.



Şekil 5.17. Segmentasyon işlemi sonrası serü üretim sistemi artırılmış eğitim veri setlerinde montaj eylemi sınıfına göre örnek sayıları.



Şekil 5.18. Segmentasyon işlemi sonrası serü üretim sistemi test veri setlerinde montaj eylemi sınıfına göre örnek sayıları.

Veri hazırlama aşamasının son adımı olarak eğitim ve test veri seti etiket değişkenlerine kategorik değişken dönüşümünün gerçekleştirilmesi amacıyla

to_categorical fonksiyonu kullanılarak tek sıcak kodlama yöntemi uygulanmıştır. Böylelikle eğitim ve test veri setlerinin çıktı değişkenleri ikili değerlere ve montaj eylemi sınıfı sayısı kadar sütunlara sahip ikili sınıf matrisleri haline gelmiştir.

5.4.4. Derin öğrenmeye dayalı sınıflandırma modellerinin geliştirilmesi

Çalışmada, oluşturulan iki veri seti (V_{eller} ve $V_{eller-vücut}$) üzerinde CNN, LSTM, GRU, BiLSTM, BiGRU, CNN-LSTM, CNN-GRU, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN modelleri geliştirilerek performansları karşılaştırılmaktadır. Modeller veri arttırma işlemi uygulanmamış 15 fps örnekleme oranındaki veri setleri (OV) ve veri arttırma işlemi gerçekleştirilmiş veri setleri (AV) üzerinde ayrı ayrı eğitilmiş ve test veri setleri üzerinde performansları değerlendirilmiştir. Seru üretim sistemindeki eğitim ve test veri setlerinin boyutları Tablo 5.8'de verilmektedir.

Tablo 5.8. Eğitim ve test veri setlerinin boyutları.

Veri Seti	Veri Seti Bölümü	Boyutu	Veri Seti	Veri Seti Bölümü	Boyutu
V_{eller}	OV	V_{eller}^{GE}	$V_{eller-vücut}$	$V_{eller-vücut}^{GE}$	(5040, 30, 258)
		V_{eller}^{GT}		$V_{eller-vücut}^{GT}$	(1242, 30, 258)
		V_{eller}^{CE}		$V_{eller-vücut}^{CE}$	(5040, 15)
	AV	V_{eller}^{CT}	$V_{eller-vücut}$	$V_{eller-vücut}^{CT}$	(1242, 15)
		V_{eller}^{GE}		$V_{eller-vücut}^{GE}$	(20176, 30, 258)
		V_{eller}^{GT}		$V_{eller-vücut}^{GT}$	(1242, 30, 258)
		V_{eller}^{CE}	$V_{eller-vücut}^{CE}$	(20176, 15)	
		V_{eller}^{CT}	$V_{eller-vücut}^{CT}$	(1242, 15)	

Modellerin eğitimi ve test edilmesi sırasında montaj hattı uygulamasında kullanılan donanımdan yararlanılmıştır. Modellerin eğitiminde tüm hiperparametreler montaj hattı uygulamasındaki değerler ile aynı olacak şekilde ayarlanmıştır: öğrenme oranı için 0,0001, kayıp fonksiyonu için kategorik çapraz-entropi, optimizasyon algoritması olarak Adam optimizasyon algoritması, eğitim turu sayısı için 500 ve yığın büyüklüğü olarak 32 değerleri belirlenmiştir.

5.4.5. Montaj eylemi tanıma modellerinin performanslarının değerlendirilmesi

Bu bölümde, çalışma kapsamında seru üretim sistemi verileri üzerinde geliştirilen derin öğrenmeye dayalı 10 montaj eylemi tanıma modelinin etkinlikleri


gerçekleştirilen deneylerin sonuçlarına dayanarak 3 bölümde incelenerek aktarılmaktadır:

- 1- Veri arttırma yaklaşımının etkisinin değerlendirilmesi,
- 2- Poz tahmini yaklaşımlarının karşılaştırılması ve
- 3- Derin öğrenme modellerinin performanslarının karşılaştırılması.


5.4.5.1. Veri arttırma yaklaşımının etkisinin değerlendirilmesi

Seru üretim sisteminde sadece ellerdeki kilit noktaların poz tahmini ile elde edilen V_{eller} veri seti ve hem ellerdeki hem de vücuttaki kilit noktaların poz tahmini ile elde edilen $V_{eller-vücut}$ veri seti ve bu veri setlerinde veri arttırma yaklaşımının uygulanmadığı (a) ve veri arttırma yaklaşımının uygulandığı (b) durumlarda eğitilen her bir modele ait karmaşıklık matrisleri EK C.1-C.20'de sunulmaktadır.

Derin öğrenmeye dayalı montaj eylemi tanıma modellerinin veri arttırma yaklaşımına göre doğruluk performans ölçütü bazında karşılaştırmalı deneysel sonuçları Şekil 5.19'da verilmektedir. Şekil 5.19(a) V_{eller} veri seti üzerinde gerçekleştirilen deneylerin sonuçlarını, Şekil 5.19(b) ise $V_{eller-vücut}$ veri seti üzerinde gerçekleştirilen deneylerin doğruluk ölçütü değerlerini yansıtmaktadır. Gerçekleştirilen deneylerin sonuçları analiz edildiğinde, veri arttırma yaklaşımının hem V_{eller} veri seti hem de $V_{eller-vücut}$ veri seti üzerinde eğitilen tüm modellerin doğruluk değerlerinde iyileşme sağladığı anlaşılmaktadır. V_{eller} veri seti üzerindeki en yüksek artış %88,0837'den %91,9485'e artmasıyla CNN-LSTM modelinde, en düşük artış ise %87,6006'dan %87,9227'ye artmasıyla LSTM modelinde meydana gelmiştir. $V_{eller-vücut}$ veri seti üzerindeki en yüksek artış %83,9775'ten %90,5797'ye artmasıyla CNN-LSTM modelinde, en düşük artış ise %85,5072'den %85,9903'e artmasıyla BiLSTM modelinde gerçekleşmiştir.




(a) V_{eller} veriseti




(b) $V_{eller-vücut}$ veriseti

Şekil 5.19. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre doğruluk performans ölçütü bazında karşılaştırılması.

Geliştirilen modellerin veri arttırma yaklaşımına göre kesinlik performans ölçütü bazında karşılaştırılması Şekil 5.20’de gösterilmektedir. Şekil 5.20(a)’da V_{eller} veri seti üzerinde geliştirilen modellerin sonuçlarına bakıldığında, veri arttırma yaklaşımının tüm modellerde kesinlik puanını arttırdığı anlaşılmaktadır. Bu artış %0,6955 ile %4,5488 arasında değişmektedir. En yüksek artış CNN-LSTM modelinde gerçekleşmiş ve %86,6675’ten %91,2163’e yükselmiştir. En düşük artış ise %86,8154’ten %87,5109’a artmasıyla LSTM modelinde meydana gelmiştir. Şekil 5.20(b)’de sunulan $V_{eller-vücut}$ veri seti üzerindeki sonuçlar, benzer şekilde veri arttırma yaklaşımı ile tüm modellerin kesinlik performans ölçütü değerlerinin yükseldiğini göstermektedir. Puan değişimi %1,1577 ile %5,0082 arasında yaşanmıştır. En yüksek artış %88,6619’dan %93,6701’e artmasıyla CNN-GRU modelinde gerçekleşmiştir.



(a) V_{eller} veriseti




(b) $V_{eller-vücut}$ veriseti


Şekil 5.20. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre kesinlik performans ölçütü bazında karşılaştırılması.

Şekil 5.21’de, geliştirilen on sınıflandırma modelinin veri arttırma yaklaşımına göre duyarlılık performans ölçütü bazında karşılaştırmalı deneysel sonuçları sunulmaktadır. Veri arttırma yaklaşımının hem V_{eller} veri seti üzerinde hem de $eller-vücut$ veri seti üzerinde eğitilen tüm modellerin duyarlılık değerleri açısından performansını pozitif yönde etkilediğini sırasıyla Şekil 5.21(a) ve Şekil 5.21(b) göstermektedir. V_{eller} veri seti üzerinde eğitilen modellerde %0,2482 ile %4,1585 arasında duyarlılık değeri artışları gerçekleşmiştir. En yüksek artış CNN-LSTM modelinde, en düşük artış LSTM modelindedir. $V_{eller-vücut}$ veri seti üzerinde gerçekleştirilen deneylerde ise modellerde %0,6735 ile %5,3659 arasında duyarlılık değeri artışları meydana

gelmiştir. En yüksek artış CNN-GRU modelinde, en düşük artış ise BiLSTM modelindedir.



(a) V_{eller} veriseti




(b) $V_{eller-vücut}$ veriseti


Şekil 5.21. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre duyarlılık performans ölçütü bazında karşılaştırılması.

Şekil 5.22 montaj eylemi tanıma modellerinin veri arttırma yaklaşımına göre F1-Skor performans ölçütü sonuçları açısından karşılaştırılmasını göstermektedir. Şekil 5.22(a)'da verilen V_{eller} veri seti üzerinde eğitilen modellerin F1-Skor sonuçları ve Şekil 5.22(b)'de verilen $V_{eller-vücut}$ veri seti üzerinde eğitilen modellerin F1-Skor sonuçları, çalışmada önerilen veri arttırma yaklaşımının tüm modellerin F1-Skor değerlerini iyileştirdiğini göstermektedir. V_{eller} veri seti üzerinde en düşük artış %86,3759'dan %86,8729'a yükseliş ile LSTM modelinde, en yüksek artış

%86,4593'den %90,8764'e artış ile CNN-LSTM modelinde görülmüştür. $V_{eller-vücut}$ veri seti üzerinde ise en düşük artış %84,1303'ten %85,1166'ya artış ile BiLSTM modelinde, en yüksek artış %87,6724'dan %92,9577'e yükseliş ile CNN-GRU modelinde elde edilmiştir.



(a) V_{eller} veriseti




(b) $V_{eller-vücut}$ veriseti

Şekil 5.22. Modellerin veri arttırma yaklaşımı uygulanma durumuna göre F1-Skor performans ölçütü bazında karşılaştırılması.


5.4.5.2. Poz tahmini yaklaşımlarının karşılaştırılması

Derin öğrenmeye dayalı montaj eylemlerinin tanınması modellerinin poz tahmini yaklaşımlarına göre doğruluk ölçütü değerlerinin karşılaştırılması Şekil 5.23'te verilmektedir. Veri arttırma yaklaşımı uygulanmadığı durumda (Şekil 5.23(a)), CNN, LSTM, GRU, BiLSTM, BiGRU, CNN-LSTM ve CNN-GRU modelleri sadece MediaPipe (Hands) poz tahmini değerleri (V_{eller}) ile eğitildiklerinde doğruluk ölçütü

açısından daha iyi performans göstermişlerdir. Özellikle LSTM ve CNN-LSTM modellerinde V_{eller} ve $V_{eller-vücut}$ veri seti üzerinde eğitime durumlarına göre doğruluk değerleri farkı sırasıyla %5,475 ve %4,1062 olmuştur. CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN modelleri ise MediaPipe (Hands) ve MediaPipe (Pose) poz tahminlerinin birleştirilmesi ile elde edilen poz değerleri ($V_{eller-vücut}$) üzerinde eğitildiğinde daha iyi sonuçlar sağlamıştır. Veri artırma yaklaşımı uygulandığı durumda (Şekil 5.23(b)), CNN, LSTM, GRU, BiLSTM, BiGRU ve CNN-LSTM modelleri V_{eller} veri seti üzerinde daha yüksek doğruluk değerleri verirken, CNN-GRU, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN modelleri ($V_{eller-vücut}$) üzerinde eğitildiğinde doğruluk ölçütü açısından daha iyi sınıflandırma performansı göstermiştir.



(a) Veri artırma yaklaşımı uygulanmayan




(b) Veri artırma yaklaşımı uygulanan


Şekil 5.23. Modellerin poz tahmini yaklaşımlarına göre doğruluk performans ölçütü bazında karşılaştırılması.

Montaj eylemi sınıflandırma modellerinin poz tahmini yaklaşımlarına göre kesinlik ölçütü değerlerinin karşılaştırılması Şekil 5.24'te verilmektedir. Modeller veri artırma yaklaşımı uygulanmadan eğitildiğinde, modellerin çoğunun kesinlik ölçütü açısından

V_{eller} veri setinde daha yüksek değerler verdiği görülmektedir. Ancak, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN olmak üzere en yüksek kesinlik değerlerine sahip üç model $V_{eller-vücut}$ veri seti üzerinde daha yüksek kesinlik değeri sağlamışlardır. Veri arttırma yaklaşımı uygulanmadığı durumda, LSTM, GRU, BiLSTM ve CNN-LSTM modelleri V_{eller} veri seti üzerinde daha iyi kesinlik değeri elde etmişlerdir. Bu modellerin iki veri seti (V_{eller} ve $V_{eller-vücut}$) üzerindeki kesinlik ölçütü değerleri farkı %1,8827 ile %4,3514 arasında değişmektedir. CNN, BiGRU, CNN-GRU, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN modelleri ise veri arttırma yaklaşımı uygulandığında $V_{eller-vücut}$ veri seti üzerinde daha yüksek kesinlik performansı göstermişlerdir. Bu modellerin iki veri seti (V_{eller} ve $V_{eller-vücut}$) üzerindeki kesinlik ölçütü değerleri farkı %1,1459 ile %3,681 arasında değişmektedir.



(a) Veri arttırma yaklaşımı uygulanmayan




(b) Veri arttırma yaklaşımı uygulanan


Şekil 5.24. Modellerin poz tahmini yaklaşımlarına göre kesinlik performans ölçütü bazında karşılaştırılması.

Montaj eylemi tanıma modellerinin poz tahmini yaklaşımlarına göre duyarlılık ölçütü değerlerinin karşılaştırılması Şekil 5.25'te gösterilmektedir. Veri arttırma yaklaşımı uygulanmayan deneylerin duyarlılık değerlerini yansıtan Şekil 5.25(a), CNN, LSTM,

GRU, BiGRU, CNN-LSTM ve CNN-GRU modellerinin V_{eller} veri seti üzerindeki deneylerde daha yüksek duyarlılık değerleri elde ettiğini göstermektedir. Özellikle LSTM ve CNN-LSTM modelleri için iki veri seti üzerinde gerçekleştirilen deneylerdeki duyarlılık değeri farkı sırasıyla %6,2166 ve %5,107 ile oldukça yüksek olduğu anlaşılmaktadır. Diğer beş modelde ise duyarlılık performansı $V_{eller-vücut}$ veri setinde daha yüksektir. Veri artırma yaklaşımı uygulanan deneylerin duyarlılık değerlerini yansıtan Şekil 5.25(b)'ye göre, BiGRU ile CNN-GRU, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN olmak üzere en yüksek duyarlılık değerlerine sahip dört model $V_{eller-vücut}$ veri seti üzerinde daha iyi duyarlılık performansı göstermişlerdir.



(a) Veri artırma yaklaşımı uygulanmayan




(b) Veri artırma yaklaşımı uygulanan


Şekil 5.25. Modellerin poz tahmini yaklaşımlarına göre duyarlılık performans ölçütü bazında karşılaştırılması.

Derin öğrenmeye dayalı sınıflandırma modellerinin poz tahmini yaklaşımlarına göre F1-Skor ölçütü değerlerinin karşılaştırılması Şekil 5.26'da sunulmaktadır. Grafikler analiz edildiğinde, veri artırma yaklaşımı uygulanmadığında (Şekil 5.26(a)), CNN,

LSTM, GRU, BiLSTM, BiGRU, CNN-LSTM ve CNN-GRU modellerinin sadece ellerdeki kilit noktaların poz verileri (V_{eller}) kullanıldığında daha iyi performans gösterdiği, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN modellerinin hem eller hem de vücuttaki kilit noktaların poz verilerinin birleştirilmesi ile elde edilen veri seti ($V_{eller-vücut}$) üzerinde daha iyi F1-Skor değerleri verdiği görülmektedir. Veri artırma yaklaşımı uygulandığında ise (Şekil 5.26(b)), CNN-GRU, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN modelleri $V_{eller-vücut}$ veri seti üzerinde, diğer modeller V_{eller} veri seti üzerinde daha iyi tahmin performans göstermiştir.



(a) Veri artırma yaklaşımı uygulanmayan



(b) Veri artırma yaklaşımı uygulanan

Şekil 5.26. Modellerin poz tahmini yaklaşımlarına göre F1-Skor performans ölçütü bazında karşılaştırılması.

5.4.5.3. Derin öğrenme modellerinin performanslarının karşılaştırılması

Tablo 5.9'da V_{eller} veri seti üzerinde veri artırma yaklaşımı uygulanmadan eğitilen derin öğrenmeye dayalı on montaj eylemi tanıma modelinin kayıp, doğruluk, kesinlik

ve F1-Skor değerleri gösterilmektedir. Hesaplamalı sonuçlar göz önünde bulundurulduğunda, en düşük kayıp değeri 0,5170 değeri ile CNN modelinde, en yüksek kayıp değeri ise 1,3303 değeri ile BiLSTM modelinde elde edilmiştir. Diğer dört performans ölçütünde BiLSTM modeli diğer modeller ile karşılaştırıldığında en düşük performansı göstermiştir. Sırasıyla %91,2238, %90,9579 ve %90,6286 değerleri ile CNN-BiGRU-CNN modeli doğruluk, duyarlılık ve F1-Skor ölçütleri açısından en yüksek performansı sağlarken, CNN-BiGRU modeli %90,4547 değeri ile en yüksek kesinlik değerini elde etmiştir. CNN modelinin LSTM, GRU, BiLSTM ve BiGRU modelleri ile hibrit kullanımı sayesinde elde edilen CNN-LSTM, CNN-GRU, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN modelleri doğruluk, kesinlik, duyarlılık ve F1-Skor performans ölçütleri açısından bu modellerin tekli kullanımlarından daha yüksek değerler sağlamıştır. Sadece LSTM modelinin kesinlik değeri %0,1479 gibi çok az bir farkla CNN-LSTM modelinin kesinlik değerinden daha fazladır.

Tablo 5.9. V_{eller} veri seti üzerinde veri arttırma yaklaşımı uygulanmadan eğitilen modellerin performansı.

Model	Kayıp	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-Skor (%)
CNN	0,5170	86,8760	86,0401	85,5735	85,7076
LSTM	0,8896	87,6006	86,8154	86,2696	86,3759
GRU	0,7072	89,2110	88,4302	87,4504	87,8584
BiLSTM	1,3303	86,2318	85,6979	84,7093	84,9837
BiGRU	0,7887	90,5797	90,3190	89,5405	89,8387
CNN-LSTM	1,0415	88,0837	86,6675	86,4997	86,4593
CNN-GRU	0,8379	90,2577	89,5433	88,1964	88,7197
CNN-BiLSTM	1,1543	90,5797	89,8946	90,0392	89,8708
CNN-BiGRU	1,0713	90,9823	90,4547	90,3206	90,2656
CNN-BiGRU-CNN	0,9266	91,2238	90,4150	90,9579	90,6286

V_{eller} veri seti üzerinde veri arttırma yaklaşımı uygulanarak geliştirilen montaj eylemi tanıma modellerinin karşılaştırmalı kayıp, doğruluk, kesinlik ve F1-Skor değerleri Tablo 5.10’da verilmektedir. En düşük kayıp değeri 0,3997 değeri ile CNN modelinde elde edilirken, en yüksek kayıp değerini 0,9091 değeri ile BiLSTM modeli vermiştir. Doğruluk, kesinlik, duyarlılık ve F1-Skor değerleri incelendiğinde, sırasıyla

%87,9227, %87,5109, %86,5178 ve %86,8729 değerleri ile on sınıflandırıcı model arasında en düşük performansı LSTM modeli göstermiştir. En yüksek performansı ise sırasıyla %92,7536, %92,3698, %91,8476 ve %92,0359 değerleri ile CNN-BiGRU-CNN hibrit modeli sağlamıştır.

Tablo 5.10. V_{eller} veri seti üzerinde veri arttırma yaklaşımı uygulanarak eğitilen modellerin performansı.

Model	Kayıp	Doğruluk	Kesinlik (%)	Duyarlılık	F1-Skor
		(%)		(%)	(%)
CNN	0,3997	88,5668	88,2698	87,4370	87,7793
LSTM	0,7506	87,9227	87,5109	86,5178	86,8729
GRU	0,4743	91,8680	91,6069	90,7875	91,1189
BiLSTM	0,9091	89,2110	88,7952	87,8143	88,1352
BiGRU	0,5924	91,0628	91,1304	90,0368	90,4462
CNN-LSTM	0,6756	91,9485	91,2163	90,6582	90,8764
CNN-GRU	0,6412	91,8680	90,9560	90,8427	90,8022
CNN-BiLSTM	0,7716	91,9485	91,6009	90,9761	91,2132
CNN-BiGRU	0,7310	92,4316	91,4695	91,7529	91,5142
CNN-BiGRU-CNN	0,6596	92,7536	92,3698	91,8476	92,0359

Tablo 5.11’de $V_{eller-vücut}$ veri seti üzerinde veri arttırma yaklaşımı uygulanmadan geliştirilen derin öğrenmeye dayalı on montaj eylemi tanıma modelinin karşılaştırmalı performans ölçütü değerleri gösterilmektedir. Tablo incelendiğinde, en düşük kayıp değerine 0,5812 değeri ile CNN modelinin, en yüksek kayıp değerine ise 1,7855 değeri ile BiLSTM modelinin sahip olduğu anlaşılmaktadır. Doğruluk, kesinlik, duyarlılık ve F1-Skor performans ölçütlerinde en düşük değerleri sırasıyla %82,126, %82,0018, %80,0530 ve %80,3993 değerleri ile LSTM modeli vermiştir. BiLSTM modeli LSTM modelinden, BiGRU modeli de GRU modelinden doğruluk, kesinlik, duyarlılık ve F1-Skor performans ölçütleri açısından daha iyi performans göstermiştir. En yüksek performans ölçütü değerleri ise sırasıyla %92,5926, %91,9941, %91,5609 ve %91,6090 değerleri ile CNN-BiGRU-CNN modelinde elde edilmiştir.

Tablo 5.11. $V_{\text{eller-vücut}}$ veri seti üzerinde veri arttırma yaklaşımı uygulanmadan eğitilen modellerin performansı.

Model	Kayıp	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-Skor (%)
CNN	0,5812	83,8969	83,7762	82,2915	82,3787
LSTM	1,4268	82,1256	82,0018	80,0530	80,3993
GRU	0,9852	87,2786	86,4526	86,3852	86,2235
BiLSTM	1,7855	85,5072	84,1532	84,7887	84,1303
BiGRU	1,0103	89,7746	89,4952	89,1704	89,2225
CNN-LSTM	1,4964	83,9775	81,8580	81,3927	81,1998
CNN-GRU	1,0015	89,2915	88,6619	87,2592	87,6724
CNN-BiLSTM	1,0593	91,8680	90,3368	90,4954	90,2951
CNN-BiGRU	0,8970	92,3510	91,4415	90,7344	90,9322
CNN-BiGRU-CNN	0,7992	92,5926	91,9941	91,5609	91,6090

Tablo 5.12’de $V_{\text{eller-vücut}}$ veri seti üzerinde veri arttırma yaklaşımı uygulanarak eğitilen on sınıflandırıcı derin öğrenme modelinin karşılaştırmalı deneysel sonuçları gösterilmektedir. CNN modelinin LSTM, GRU, BiLSTM ve BiGRU modelleri ile hibrit kullanılması, bu modellerin tekli kullanılmaları durumundaki performanslarını (doğruluk, kesinlik, duyarlılık ve F1-Skor performans ölçütleri açısından) oldukça iyileştirmiştir. Kayıp, doğruluk, kesinlik, duyarlılık ve F1-Skor olmak üzere beş performans ölçütünde de en iyi değerlere sırasıyla 0,4627, %95,9742, %96,0508, %94,9372 ve %95,3904 değerleri ile CNN-BiGRU-CNN modeli ile ulaşılmıştır.

Tablo 5.12. $V_{\text{eller-vücut}}$ veri seti üzerinde veri arttırma yaklaşımı uygulanarak eğitilen modellerin performansı.

Model	Kayıp	Doğruluk	Kesinlik (%)	Duyarlılık	F1-Skor
		(%)		(%)	(%)
CNN	0,5123	87,7617	88,5959	86,8723	87,2706
LSTM	1,1571	84,0580	83,1595	81,4431	81,8935
GRU	0,6041	89,2110	88,8704	88,8788	88,7283
BiLSTM	1,6350	85,9903	85,5426	85,4622	85,1166
BiGRU	0,6337	90,9018	91,1644	90,2409	90,4806
CNN-LSTM	0,8294	90,5797	89,3336	88,7758	88,9024
CNN-GRU	0,5118	93,9614	93,6701	92,6251	92,9577
CNN-BiLSTM	0,9204	92,7536	91,7468	92,0351	91,7057
CNN-BiGRU	0,5931	94,6055	94,1132	93,5633	93,7723
CNN-BiGRU- CNN	0,4627	95,9742	96,0508	94,9372	95,3904

5.5. Montaj Hattı ve Seru Üretim Sistemi Uygulama Sonuçlarının Karşılaştırılması

Veri arttırma yaklaşımlarının etkisi incelendiğinde hem montaj hattındaki deneylerde hem de seru üretim sistemindeki deneylerde, veri arttırma yaklaşımının uygulanmasıyla V_{eller} veri seti ve $V_{\text{eller-vücut}}$ veri seti üzerinde geliştirilen tüm montaj eylemi tanıma modellerinin doğruluk, kesinlik, duyarlılık ve F1-Skor olmak üzere dört performans ölçütü değerlerinde iyileşme olduğu belirlenmiştir. Bu iyileşme $V_{\text{eller-vücut}}$ veri seti üzerinde eğitilen modellerde daha belirgindir. Montaj hattı uygulamalarında V_{eller} veri setinde doğruluk ölçütünde en yüksek artış %4,5012 iken, $V_{\text{eller-vücut}}$ veri setinde %7,7859'dur. Kesinlik değerlerinde V_{eller} veri setinde en yüksek artış %4,5029 iken, $V_{\text{eller-vücut}}$ veri setinde %9,4417'dir. Duyarlılık değerlerinde V_{eller} veri setinde en yüksek artış %4,9283 iken, $V_{\text{eller-vücut}}$ veri setinde %8,958'dir. F1-Skor değerlerinde ise V_{eller} veri setinde en yüksek artış % 4,7844 iken, $V_{\text{eller-vücut}}$ veri setinde %9,131'dir. Seru üretim sisteminde ise, V_{eller} veri setinde doğruluk ölçütünde en yüksek artış %3,8648 iken, $V_{\text{eller-vücut}}$ veri setinde %6,6022'dir. Kesinlik değerlerinde V_{eller} veri setinde en yüksek artış %4,5488 iken, $V_{\text{eller-vücut}}$ veri setinde %7,4756'dır. Duyarlılık değerlerinde V_{eller} veri setinde en yüksek artış %4,1585 iken, $V_{\text{eller-vücut}}$ veri setinde %7,3831'dir. F1-Skor değerlerinde ise V_{eller} veri setinde en yüksek artış %4,4171 iken, $V_{\text{eller-vücut}}$ veri setinde %7,7026'dır.

Poz tahmini yaklaşımlarının karşılaştırılması sonucunda, montaj hattı uygulamasında veri arttırma yaklaşımı uygulanmayan deneylerde CNN-LSTM hariç tüm modellerin sadece MediaPipe holistic (hands) kullanılarak oluşturulan V_{eller} veri seti yerine MediaPipe holistic (hands)'in poz tahminleri ile MediaPipe holistic (pose)'un poz tahminlerinin birleştirilmesi ile elde edilen $V_{eller-vücut}$ veri seti üzerinde geliştirildiklerinde doğruluk, kesinlik, duyarlılık ve F1-Skor olmak üzere dört performans ölçütü açısından daha iyi sınıflandırma gücüne sahip oldukları anlaşılmıştır. İki veri seti üzerindeki deneylerde doğruluk, kesinlik, duyarlılık ve F1-Skor ölçütü değerlerindeki en yüksek fark sırasıyla %5,9611 ile BiGRU modelinde, %7,0943 ile CNN-BiGRU modelinde, %6,6142 ile CNN-BiLSTM modelinde ve %6,8018 ile yine CNN-BiLSTM modelinde gerçekleşmiştir. Veri arttırma yaklaşımı uygulanan deneylerde ise LSTM hariç tüm modeller MediaPipe holistic (hands)'in poz tahminleri ile MediaPipe holistic (pose)'un poz tahminlerinin birleştirilmesi ile elde edilen $V_{eller-vücut}$ veri seti üzerinde daha iyi performans göstermiştir. Bu iki veri seti üzerindeki deney sonuçlarına göre ise doğruluk, kesinlik, duyarlılık ve F1-Skor ölçütü değerlerindeki en yüksek fark sırasıyla %5,9611 ile CNN modelinde, %6,9392 ile CNN-GRU modelinde, %6,7996 ile CNN modelinde ve %6,7965 ile CNN-GRU modelinde elde edilmiştir. Seru üretim sistemi uygulamasında ise, veri arttırma yaklaşımı uygulanmayan deneylerde modellerin çoğunun MediaPipe holistic (hands) kullanılarak oluşturulan V_{eller} veri seti üzerinde daha iyi doğruluk, kesinlik, duyarlılık ve F1-Skor performansı sağladığı, en yüksek performans ölçütü skorlarına sahip CNN-BiLSTM, CNN-BiGRU, CNN-BiGRU-CNN modellerinin ise MediaPipe holistic (hands)'in poz tahminleri ile MediaPipe holistic (pose)'un poz tahminlerinin birleştirilmesi ile elde edilen $V_{eller-vücut}$ veri seti üzerinde geliştirildiklerinde daha iyi performans gösterdikleri anlaşılmıştır. İki veri seti üzerindeki deneylerde doğruluk, kesinlik, duyarlılık ve F1-Skor ölçütü değerlerindeki en yüksek fark sırasıyla %5,475, %4,8136, %6,2166 ve %5,9766 değerleri ile LSTM modelinde gerçekleşmiştir. Veri arttırma yaklaşımı uygulanan deneylerde ise CNN-GRU, CNN-BiLSTM, CNN-BiGRU ve CNN-BiGRU-CNN modelleri MediaPipe holistic (hands)'in poz tahminleri ile MediaPipe holistic (pose)'un poz tahminlerinin birleştirilmesi ile elde edilen $V_{eller-vücut}$ veri seti üzerinde tüm performans ölçütlerine göre daha iyi sonuçlar vermiştir. Bu iki veri seti üzerindeki deneyler sonuçlarına göre ise doğruluk, kesinlik, duyarlılık ve F1-Skor ölçütü değerlerindeki en yüksek fark sırasıyla %3,8647,

%4,3514, %5,0747 ve %4,9794 deęerleri ile LSTM modelinde gerekleŒmiŒtir. Burada LSTM modeli V_{eller} veri setinde daha yksek deęerler elde etmiŒtir.

Derin ęrenme modellerinin deneyler ile karŒılaŒtırılması sonucunda, hem montaj hattı uygulamasında hem de seru retim sistemi uygulamasında CNN modelinin LSTM, GRU, BiLSTM ve BiGRU modelleri ile hibrit kullanılmasının, LSTM, GRU, BiLSTM ve BiGRU modellerinin tekli kullanılmaları durumundaki doęruluk, kesinlik, duyarlılık ve F1-Skor performans ltleri aısından performanslarını genel olarak iyileŒtirdięi sonucuna varılmıŒtır. Montaj hattında gerekleŒtirilen deneylerde, V_{eller} veri seti zerinde veri arttırma yaklaŒımı uygulanmadan gerekleŒtirilen deneylerde, en yksek doęruluk deęerini veren CNN-BiGRU modeli ile CNN-BiGRU-CNN modeli aynı doęruluk deęerine sahiptir. Bu modellerden CNN-BiGRU modeli duyarlılık ltne gre daha iyi performans gsterirken, CNN-BiGRU-CNN modeli kesinlik ve F1-Skor ltne gre daha iyi performans gstermiŒtir. $V_{eller-vcut}$ veri seti zerinde veri arttırma yaklaŒımı uygulanmadan gerekleŒtirilen deneylerde duyarlılık lt hari tm ltlerde CNN-BiGRU modeli daha iyi sonular vermiŒtir. V_{eller} veri seti ve $V_{eller-vcut}$ veri seti zerinde veri arttırma yaklaŒımı uygulanarak gerekleŒtirilen deneylerde ise CNN-BiGRU-CNN modeli tm performans ltleri aısından en iyi deęerleri saęlamıŒtır. En iyi montaj eylemi tanıma doęruluęu gsteren model $V_{eller-vcut}$ veri seti zerinde veri arttırma yaklaŒımı uygulanarak eęitilen ve %97,3236 doęruluk deęerine sahip CNN-BiGRU-CNN modeli olmuŒtur. Seru retim sisteminde gerekleŒtirilen deneylerde ise V_{eller} , $V_{eller-vcut}$ veri setleri zerinde veri arttırma yaklaŒımı uygulanarak ve veri arttırma yaklaŒımı uygulanmadan gerekleŒtirilen her bir deney kombinasyonunda doęruluk, kesinlik, duyarlılık ve F1-Skor performans ltleri aısından en iyi performansı genel olarak nerilen CNN-BiGRU-CNN modeli gstermiŒtir. En iyi montaj eylemi tanıma doęruluęu gsteren model $V_{eller-vcut}$ veri seti zerinde veri arttırma yaklaŒımı uygulanarak eęitilen ve %95,9742 doęruluk deęerine sahip CNN-BiGRU-CNN modeli olmuŒtur.

6. SONUÇ VE ÖNERİLER

Günümüz ortamında, artan sayıda ürün çeşidine ve değişen talep hacimlerine hızlı bir şekilde uyum sağlamak ve aynı zamanda yüksek kalite ve verimlilik elde etmek için montaj sistemlerinin esnek ve değişebilir olması gerekmektedir. Müşteriler, değişen taleplere hızlı yanıt veren ve dalgalı piyasa ortamına uyum sağlayan yüksek kaliteli ürünleri tercih etmektedir. Firmalar, montaj hatlarını serü üretim sistemlerine dönüştürerek, gerekli işgücü sayısını ve çalışma alanını azaltarak karlılıklarını artırırken, üretim esnekliğini ve verimliliğini de arttırabilir. Buna ek olarak, üretim birimlerinde önerilen proses kontrol ve otomasyon sistemlerini kullanarak süreç bilgilerini çok daha düşük maliyetle yönetebilir ve optimize edebilirler. Serü üretim sisteminin hızla gelişen teknolojileri entegre ederek dijitalleşmesi, montaj süreçlerinden büyük miktarda veri toplamayı mümkün kılmaktadır.

Bu çalışmada, serü üretim sisteminin üretim kontrolüne yönelik ileri teknolojiler ve derin öğrenme teknikleri kullanılarak altı bileşenli bir zeki serü üretim sistemi kontrolü modeli önerilmiştir. Bu model, montaj süreci izlendiğinde ve çalışan yanlış sırayla bir işlem gerçekleştirdiğinde çalışanı uyaran ve sonraki aşamalarda ürünün montajını engelleyebilecek bir yapıda tasarlanmıştır. Böylece gereksiz yeniden işleme zamanını ortadan kaldırır. Ayrıca gerçek zamanlı veri yakalama ve toplama, derin öğrenme modellerine dayalı akıllı veri işleme ve akıllı karar verme süreçleri ile serü üretim sisteminin aşağıdaki yetkinliklere sahip olabilir;

- Ürünün, ürün bileşenlerinin, montaj araçlarının, çalışanın, sürecin, envanterin ve çalışma ortamının gerçek zamanlı izlenmesi,
- İleri teknoloji destekli montaj işlemleri,
- Kesintisiz montaj süreçleri için yatailerin optimum beslenmesi,
- Verimli stok yönetimi,
- Çalışan performansının gerçek zamanlı izlenmesi,
- Çalışma ortamında ergonomik olarak uygun koşulların sağlanması,

- Çalışanın sürekli eğitimi ve gelişimi,
- Montaj görevleri hakkında çalışanı bilgilendirmek ve desteklemek,
- Sistem katılımcıları (çalışanlar, yönetim, depolar, tedarikçiler, iş istasyonları ve müşteriler) arasında gerçek zamanlı ve kesintisiz bilgi paylaşımı,
- Otomatik uyarı sistemi sayesinde hızlı tepki verilerek faaliyetlerin güncellenmesi,
- Yöneticilerin kararlarını gerçek zamanlı montaj sürecine ve tahminleyici dayalı analize dayalı vermeleri,
- Gerçek zamanlı kapasite planlama ve işgücü yönetimi,
- Müşterilerin siparişlerinin durumu hakkında bilgi sahibi olmaları,
- Yatailerin değişikliklere ve beklenmedik durumlara gerçek zamanlı olarak cevap verme esnekliğine sahip olması.

Çalışmanın ilerleyen aşamasında kavramsal modelin bünyesinde bulunan montaj eylemlerinin tanınması modelinin metodolojisi geliştirilmiştir. Bu metodolojiye temel olarak, poz tahmini verilerini kullanan hibrit CNN-BiGRU-CNN montaj eylemlerinin tanınması modeli önerilmiştir. Modelde, iskelet konumları verileri poz tahmini yaklaşımlarından MediaPipe Holistic altyapısından faydalanılarak elde edilmiştir. Poz tahmini ile verileri elde etme aşamasında çalışmada iki yaklaşım karşılaştırılmaktadır. İlki sadece ellerdeki kilit noktaların poz verilerini sağlayan MediaPipe(Hands) modelinin kullanılmasıdır. İkincisi ise MediaPipe(Hands) modeli sayesinde elde edilen ellerdeki kilit noktaların poz tahmini verilerinin MediaPipe(Pose) modeli sayesinde elde edilen vücuttaki kilit noktaların poz tahmini verileri ile birleştirilmesidir. Sınıflandırıcı modellerin performansını arttırmak için aşağı örnekleme ve ölçeklemeye dayalı iki aşamalı bir veri arttırma yaklaşımı önerilmiştir. Montaj eylemlerinin sınıflandırılması için CNN ve RNN'e dayalı mimariler ve bu mimarilerin birlikte kullanımları ile geliştirilen uzamsal ve zamansal bağımlılıkları aynı anda yakalama yeteneğine sahip hibrit modeller olmak üzere derin öğrenmeye dayalı on adet model geliştirilmiştir. Modellerin etkinliklerinin değerlendirilmesi amacıyla, Federal Elektrik Firmasında otomatik sigorta ürünü montaj eylemleri için serü üretim sistemi ve montaj hattı üzerinde tek bir kamera ile görüntü verileri toplanarak uygulamaları gerçekleştirilmiştir.

Gerçekleştirilen deney sonuçları incelendiğinde, hem montaj hattındaki deneylerde hem de serü üretim sistemindeki deneylerde, çalışmada önerilen veri artırma yaklaşımının V_{eller} veri seti ve $V_{eller-vücut}$ veri seti üzerinde geliştirilen tüm montaj eylemi tanıma modellerinde doğruluk, kesinlik, duyarlılık ve F1-Skor performans ölçütü değerlerinin artmasını sağladığı görülmüştür. Montaj hattı uygulamalarında doğruluk ölçütü değerinde yaklaşık %8'e, serü üretim sisteminde ise yaklaşık %7'ye varan iyileşmeler sağlamıştır. Poz tahmini yaklaşımları karşılaştırıldığında, montaj hattı sisteminde veri artırma yaklaşımı uygulanmadan eğitim gerçekleştirildiğinde CNN-LSTM hariç tüm modellerin, veri artırma yaklaşımı uygulandığında ise LSTM hariç tüm modellerin $V_{eller-vücut}$ veri seti üzerinde eğitildiklerinde daha yüksek performans ölçütü değerleri elde ettikleri görülmüştür. Montaj hattı sistemindeki iki veri seti üzerinde doğruluk ölçütü değeri farkı %6'ya ulaşmıştır. Serü üretim sistemi uygulamasında ise, veri artırma yaklaşımı uygulanmayan deneylerde modellerin çoğunun V_{eller} veri seti üzerinde daha iyi performansı gösterdiği, fakat en yüksek performans ölçütü skorlarına sahip modellerin $V_{eller-vücut}$ veri seti üzerinde geliştirildiklerinde daha iyi performans gösterdikleri anlaşılmıştır.

Montaj hattı ve serü üretim sistemi veri setleri üzerindeki deneylerde CNN modelinin LSTM, GRU, BiLSTM ve BiGRU modelleri ile hibrit kullanılmasının, bu modellerin tekli kullanılmaları durumundaki doğruluk, kesinlik, duyarlılık ve F1-Skor performans ölçütleri açısından performanslarını genel olarak iyileştirdiği gözlemlenmiştir. Bu dört ölçüt açısından en iyi değerler, MediaPipe (Hands) ve MediaPipe (Pose) poz tahmini modellerinin hibrit kullanımı ile elde edilen veri setleri üzerinde önerilen hibrit CNN-BiGRU-CNN modelinin geliştirilmesi sayesinde elde edilmiştir. Bu değerler montaj hattında sırasıyla %97, %97, %97 ve %97 iken serü üretim sisteminde ise %96, %96, %95 ve %95 olduğu gözlemlenmiştir.

Önerilen zeki serü üretim sistemi kavramsal modeli ile üretim verimliliğinin artarak ürünlerin kalite maliyetinin azalabileceği değerlendirilebilir. Önerilen sistem modelleri derin öğrenmeye dayalı insan aktivite tanıma, nesne tespiti, duruş analizi ve iç ortam kalite analizini içermektedir. İnsan aktivite tanınması çalışması alanına giren montaj eylemlerinin tanınması modeli bu çalışmada uygulanmıştır. Montaj eylemlerinin tanınması modelinin sistemde kullanılması ile montaj eylemlerinin doğru sırada gerçekleşip gerçekleşmediği belirlenebilecektir. Ayrıca modelin uygulanması sonucu elde edilebilecek montaj süreleri bilgisi sayesinde gerçek zamanlı performans

değerlendirme ve gerçek zamanlı üretim ve kapasite planlama çalışmaları da yürütülebileceği, çalışanların beceri düzeylerinin belirlenerek eğitim ihtiyaçlarının tespit edilebileceği değerlendirilmektedir. Ancak çalışmada sadece montaj eylemlerinin tanınması modelinin uygulamasının gerçekleştirilmesi çalışmanın sınırlılığı olarak belirtilebilir. Gelecek çalışmalarda, serü üretim sistemi için önerilen gerçek zamanlı kontrol sistemindeki diğer modellerin de uygulanması planlanabilir. Gelecek çalışması olarak, serü üretim sistemi için önerilen diğer modellerin uygulanması planlanabilir.

KAYNAKLAR

- Abbaspour, S., Fotouhi, F., Sedaghatbaf, A., Fotouhi, H., Vahabi, M., & Linden, M. (2020). A comparative analysis of hybrid deep learning models for human activity recognition. *Sensors*, 20(19), 1-14. <https://doi.org/10.3390/s20195707>
- Abdullah, M. (2018). *Impact of Skill: Seru vs Classical Assembly Line* [Doktora tezi]. Ohio University
- Abobakr, A., D. Nahavandi, M. Hossny, J. Iskander, M. Attia, S. Nahavandi, & M. Smets. (2019). RGB-D Ergonomic Assessment System of Adopted Working Postures. *Applied Ergonomics*, 80: 75–88. <https://doi.org/10.1016/j.apergo.2019.05.004>
- Aehnelt, M., Gutzeit, E., & Urban, B. (2014). Using activity recognition for the tracking of assembly processes: Challenges and requirements. *WOAR*, 2014, 12-21.
- Ahad, M. A. R., Antar, A. D., & Ahmed, M. (2020). *IoT Sensor-based Activity Recognition*. Springer.
- Ahn, J., Shin, D., Kim, K., & Yang, J. (2017). Indoor air quality analysis using deep learning with sensor data. *Sensors*, 17(11), 2476. <https://doi.org/10.3390/s17112476>
- Akyol, K. (2020). Comparing of Deep Neural Networks and Extreme Learning Machines Based on Growing and Pruning Approach. *Expert Systems with Applications*, 140: 112875. <https://doi.org/10.1016/j.eswa.2019.112875>
- Alawneh, L., Alsarhan, T., Al-Zinati, M., Al-Ayyoub, M., Jararweh, Y., & Lu, H. (2021). Enhancing human activity recognition using deep learning and time series augmented data. *Journal of Ambient Intelligence and Humanized Computing*, 12(12), 10565-10580. <https://doi.org/10.1007/s12652-020-02865-4>
- Al-Amin, M. (2021). *Sensor data based adaptive models for assembly worker training in cyber manufacturing* [Doktora tezi] Missouri University of Science and Technology
- Al-Amin, M., Tao, W., Doell, D., Lingard, R., Yin, Z., Leu, M. C., & Qin, R. (2019). Action recognition in manufacturing assembly using multimodal sensor fusion. *Procedia Manufacturing*, 39, 158-167. <https://doi.org/10.1016/j.promfg.2020.01.288>
- Al-Amin, M., Qin, R., Moniruzzaman, M., Yin, Z., Tao, W., & Leu, M. C. (2023). An individualized system of skeletal data-based CNN classifiers for action recognition in manufacturing assembly. *Journal of Intelligent Manufacturing*, 34, 633-649. <https://doi.org/10.1007/s10845-021-01815-x>

- Al-Amin, M., Qin, R., Tao, W., Doell, D., Lingard, R., Yin, Z., & Leu, M. C. (2022). Fusing and refining convolutional neural network models for assembly action recognition in smart manufacturing. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 236(4), 2046-2059. <https://doi.org/10.1177/0954406220931547>
- Andrianakos, G., Dimitropoulos, N., Michalos, G., & Makris, S. (2019). An approach for monitoring the execution of human based assembly operations using machine learning. *Procedia Cirp*, 86, 198-203. <https://doi.org/10.1016/j.procir.2020.01.040>
- Angerbauer, S., Palmanshofer, A., Selinger, S., & Kurz, M. (2021). Comparing human activity recognition models based on complexity and resource usage. *Applied Sciences*, 11(18), 1-29. <https://doi.org/10.3390/app11188473>
- Asghari, V., Leung, Y. F., & Hsu, S. C. (2020). Deep neural network based framework for complex correlations in engineering metrics. *Advanced Engineering Informatics*, 44, 1-16. <https://doi.org/10.1016/j.aei.2020.101058>
- Atalaa, B. A., Ahmed Alenany, A. H., & Ziedan, I. (2020). Effect of Data Segmentation on the Quality of Human Activity Recognition. *East African Scholars Journal of Engineering and Computer Sciences*. 3(7), 133-145. doi:10.36349/easjecs.2020.v03i07.001
- Athira, V., Geetha, P., Vinayakumar, R., & Soman, K. P. (2018). Deepairnet: Applying recurrent networks for air quality prediction. *Procedia computer science*, 132, 1394-1403. <https://doi.org/10.1016/j.procs.2018.05.068>
- Athota, R. K., & Sumathi, D. (2022). Human activity recognition based on hybrid learning algorithm for wearable sensor data. *Measurement: Sensors*, 24, 1-14. <https://doi.org/10.1016/j.measen.2022.100512>
- Attal, F., Mohammed, S., Dedabrishvili, M., Chamroukhi, F., Oukhellou, L., & Amirat, Y. (2015). Physical human activity recognition using wearable sensors. *Sensors*, 15(12), 31314-31338. <https://doi.org/10.3390/s151229858>
- Ayough, A., Hosseinzadeh, M., & Motameni, A. (2020). Job rotation scheduling in the seru system: shake enforced invasive weed optimization approach. *Assembly Automation*, 40(3), 461-474. <https://doi.org/10.1108/AA-07-2019-0126>
- Azadi, B., Haslgrübler, M., Sopidis, G., Murauer, M., Anzengruber, B., & Ferscha, A. (2019, June, 5-7). Feasibility analysis of unsupervised industrial activity recognition based on a frequent micro action. In *Proceedings of the 12th ACM International Conference on Pervasive Technologies Related to Assistive Environments*. Rhodes, Greece. <https://doi.org/10.1145/3316782.3322749>
- Aziz, F., Metwally, O., Weller, P., Schneider, U., & Huber, M. F. (2022, March). A MIMO Radar-Based Metric Learning Approach for Activity Recognition. In *2022 IEEE Radar Conference (RadarConf22)* (pp. 1-6). IEEE. USA. <https://doi.org/10.1109/RadarConf2248738.2022.9764202>
- Bahukhandi, U., & Gupta, S. (2021). Yoga pose detection and classification using machine learning techniques. *International Research Journal of Modernization in Engineering Technology and Science*, 3(12), 186-191.

- Banerjee, A., Paul, S., & Bhattacharya, S. (2023). Advanced Agricultural Systems: Identification, Crop Yields and Recommendations Using Image-Processing Techniques and Machine-Learning Algorithms. In *Machine Learning, Blockchain, and Cyber Security in Smart Environments* (pp. 81-97). Chapman and Hall/CRC.
- Banos, O., Galvez, J. M., Damas, M., Pomares, H., & Rojas, I. (2014). Window size impact in human activity recognition. *Sensors*, 14(4), 6474-6499. <https://doi.org/10.3390/s140406474>
- Bay, M., & Çiçek, E. (2007). Tam Zamanında Üretim Sistemlerinde Hata Önleyiciler: Poka. *Karamanoğlu Mehmetbey Üniversitesi Sosyal Ve Ekonomik Araştırmalar Dergisi*, 2007(3), 53–62.
- Bazarevsky, V., Grishchenko, I., Raveendran, K., Zhu, T., Zhang, F., & Grundmann, M. (2020). Blazepose: On-device real-time body pose tracking. *arXiv preprint arXiv:2006.10204*. <https://doi.org/10.48550/arXiv.2006.10204>
- Bersch, S. D., Azzi, D., Khusainov, R., Achumba, I. E., & Ries, J. (2014). Sensor data acquisition and processing parameters for human activity classification. *Sensors*, 14(3), 4239-4270. <https://doi.org/10.3390/s140304239>
- Bianchi, V., Bassoli, M., Lombardo, G., Fornacciari, P., Mordonini, M., & De Munari, I. (2019). IoT wearable sensor and deep learning: An integrated approach for personalized human activity recognition in a smart home environment. *IEEE Internet of Things Journal*, 6(5), 8553-8562. <https://doi.org/10.1109/JIOT.2019.2920283>
- Bilen, H., Fernando, B., Gavves, E., Vedaldi, A., & Gould, S. (2016). Dynamic image networks for action recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3034-3042). IEEE. USA. <https://doi.org/10.1109/CVPR.2016.331>
- Cao, X., Liu, Y., Wang, J., Liu, C., & Duan, Q. (2020). Prediction of dissolved oxygen in pond culture water based on K-means clustering and gated recurrent unit neural network. *Aquacultural Engineering*, 91, 102122. <https://doi.org/10.1016/j.aquaeng.2020.102122>
- Cao, Z., Simon, T., Wei, S. E., & Sheikh, Y. (2017). Realtime multi-person 2d pose estimation using part affinity fields. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1302-1310). IEEE. USA. <https://doi.org/10.1109/CVPR.2017.143>
- Chen, C., Wang, T., Li, D., & Hong, J. (2020a). Repetitive assembly action recognition based on object detection and pose estimation. *Journal of Manufacturing Systems*, 55, 325-333. <https://doi.org/10.1016/j.jmsy.2020.04.018>
- Chen, C., Zhang, C., Wang, T., Li, D., Guo, Y., Zhao, Z., & Hong, J. (2020b). Monitoring of Assembly Process Using Deep Learning Technology. *Sensors*, 20(15), 1-18. <https://doi.org/10.3390/s20154208>
- Chen, C., Zhao, X., Wang, J., Li, D., Guan, Y., & Hong, J. (2022). Dynamic graph convolutional network for assembly behavior recognition based on attention mechanism and multi-scale feature fusion. *Scientific Reports*, 12(1), 1-13. <https://doi.org/10.1038/s41598-022-11206-8>

- Chen, J., Zeng, G. Q., Zhou, W., Du, W., & Lu, K. D. (2018). Wind speed forecasting using nonlinear-learning ensemble of deep learning time series prediction and extremal optimization. *Energy conversion and management*, 165, 681-695. <https://doi.org/10.1016/j.enconman.2018.03.098>
- Chen, J., Sun, Y., & Sun, S. (2021). Improving human activity recognition performance by data fusion and feature engineering. *Sensors*, 21(3), 1-22. <https://doi.org/10.3390/s21030692>
- Chung, S., Lim, J., Noh, K. J., Kim, G., & Jeong, H. (2019). Sensor data acquisition and multimodal sensor fusion for human activity recognition using deep learning. *Sensors*, 19(7), 1-20. <https://doi.org/10.3390/s19071716>
- Coronado, E., Fukuda, K., Ramirez-Alpizar, I. G., Yamanobe, N., Venture, G., & Harada, K. (2021, September). Assembly Action Understanding from Fine-Grained Hand Motions, a Multi-camera and Deep Learning Approach. In *2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (pp. 2628-2634). IEEE. <https://doi.org/10.1109/IROS51168.2021.9636715>
- Csizmadia, G., Liszkai-Peres, K., Ferdinandy, B., Miklósi, Á., & Konok, V. (2022). Human activity recognition of children with wearable devices using LightGBM machine learning. *Scientific Reports*, 12(1), 1-10. <https://doi.org/10.1038/s41598-022-09521-1>
- Cui, Z., Ke, R., Pu, Z., & Wang, Y. (2018). Deep bidirectional and unidirectional LSTM recurrent neural network for network-wide traffic speed prediction. arXiv preprint arXiv:1801.02143. <https://doi.org/10.48550/arXiv.1801.02143>
- Çalışkan, E., İşleyen, S. K., & Çerçioğlu, H. (2021). A mixed integer mathematical model for loading problem in seru manufacturing systems and matheuristic solution approach. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(2), 793-806. <https://doi.org/10.17341/gazimmfd.603882>
- Dairi, A., Harrou, F., Senouci, M., & Sun, Y. (2018). Unsupervised obstacle detection in driving environments using deep-learning-based stereovision. *Robotics and Autonomous Systems*, 100, 287-301. <https://doi.org/10.1016/j.robot.2017.11.014>
- Dang, L. M., Min, K., Wang, H., Piran, M. J., Lee, C. H., & Moon, H. (2020). Sensor-based and vision-based human activity recognition: A comprehensive survey. *Pattern Recognition*, 108, 1-24. <https://doi.org/10.1016/j.patcog.2020.107561>
- Dang, Q. V. (2022). Machine Learning for Intrusion Detection Systems: Recent Developments and Future Challenges. In *Real-Time Applications of Machine Learning in Cyber-Physical Systems* (pp. 93-118). IGI Global. <https://doi.org/10.4018/978-1-7998-9308-0.ch007>
- Deepthi, T. V. (2020). *Seru system for productivity enhancement and sustainable planning* [Doktora Tezi] K L University
- Deepthi, T. V., Ramakotaiah, K., & Krishnaveni, K. (2019b). Research on performance of multi-skilled workers for sustainable production planning in seru production systems. *International Journal of Innovative Technology and Exploring Engineering*, 8(10), 1-13.

- Deepthi, T. V., Ramakotaiah, K., Manupati, V. K., & Gangal, C. (2019a). Investigating the performance improvement by conversion of assembly line configuration to a pure cell system in manufacturing industry. *European Journal of Industrial Engineering*, 13(6), 723-745. <https://doi.org/10.1504/EJIE.2019.104281>
- de Treville, S., Ketokivi, M., & Singhal, V. R. (2017). Competitive manufacturing in a high-cost environment: Introduction to the special issue. *Journal of Operations Management, Forthcoming, Georgia Tech Scheller College of Business Research Paper*, 17-9.
- Dehghani, A., Glatard, T., & Shihab, E. (2019b). Subject cross validation in human activity recognition. *arXiv preprint arXiv:1904.02666*. <https://doi.org/10.48550/arXiv.1904.02666>
- Dehghani, A., Sarbishei, O., Glatard, T., & Shihab, E. (2019a). A quantitative comparison of overlapping and non-overlapping sliding windows for human activity recognition using inertial sensors. *Sensors*, 19(22), 1-19. <https://doi.org/10.3390/s19225026>
- Dileep, A. S., Nabilah, S. S., Sreeju, S., Farhana, K., & Surumy, S. (2022, March). Suspicious Human Activity Recognition using 2D Pose Estimation and Convolutional Neural Network. In *2022 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET)* (pp. 19-23). IEEE. India. <https://doi.org/10.1109/WiSPNET54241.2022.9767152>
- Diren, D. D., & Boran, S. (2021). Fault Detection in Manufacturing Companies with Ensemble Machine Learning Method. *İşletme Araştırmaları Dergisi*, 13(4), 3728-3741.
- Diro, A. A., & Chilamkurti, N. (2018). Distributed attack detection scheme using deep learning approach for Internet of Things. *Future Generation Computer Systems*, 82, 761-768. <https://doi.org/10.1016/j.future.2017.08.043>
- Dong, Y. (2018). An application of deep neural networks to the in-flight parameter identification for detection and characterization of aircraft icing. *Aerospace Science and Technology*, 77, 34-49. <https://doi.org/10.1016/j.ast.2018.02.026>
- Doppler, J. P., Günther, L. C., & Haar, C. (2021). Double-stage methodology for activity recognition in manual assembly. *Procedia CIRP*, 104, 423-428. <https://doi.org/10.1016/j.procir.2021.11.071>
- Dua, N., Singh, S. N., & Semwal, V. B. (2021). Multi-input CNN-GRU based human activity recognition using wearable sensors. *Computing*, 103(7), 1461-1478. <https://doi.org/10.1007/s00607-021-00928-8>
- Dutta, A., Kumar, S., & Basu, M. (2020). A gated recurrent unit approach to bitcoin price prediction. *Journal of Risk and Financial Management*, 13(2), 23. <https://doi.org/10.3390/jrfm13020023>
- Dwarampudi, M., & Reddy, N. V. (2019). Effects of padding on LSTMs and CNNs. *arXiv preprint arXiv:1903.07288*. <https://doi.org/10.48550/arXiv.1903.07288>

- Eerdeken, A., Deruyck, M., Fontaine, J., Martens, L., De Poorter, E., Plets, D., & Joseph, W. (2020, August). Resampling and Data Augmentation for Equines' Behaviour Classification Based on Wearable Sensor Accelerometer Data Using a Convolutional Neural Network. In *2020 International Conference on Omni-layer Intelligent Systems (COINS)* (pp. 1-6). IEEE. Spain. <https://doi.org/10.1109/COINS49042.2020.9191639>
- ElMaraghy, H., & ElMaraghy, W. (2016). Smart adaptable assembly systems. *Procedia CIRP*, 44, 4-13. <https://doi.org/10.1016/j.procir.2016.04.107>
- Elshaboury, N., Elshourbagy, M., Al-Sakkaf, A., & Abdelkader, E. M. (2021, May). Rainfall forecasting in arid regions using an ensemble of artificial neural networks. In *Journal of Physics: Conference Series* (Vol. 1900, No. 1, p. 012015). IOP Publishing. <https://doi.org/10.1088/1742-6596/1900/1/012015>
- Estrada, G., Riba, C., & Lloveras, J. (2007, 28-31, July). An approach to avoid quality assembly issues since product design stage. J.-C. Bocquet (Ed.), In *DS 42: Proceedings of ICED 2007, the 16th International Conference on Engineering Design*, Paris, France, (pp. 233-234).
- Fan, J., & Dong, J. (2003, October). Intelligent virtual assembly planning with integrated assembly model. In *SMC'03 Conference Proceedings. 2003 IEEE International Conference on Systems, Man and Cybernetics. Conference Theme-System Security and Assurance* (Cat. No. 03CH37483) (Vol. 5, pp. 4803-4808). IEEE. USA. <https://doi.org/10.1109/ICSMC.2003.1245743>
- Fu, R., Zhang, Z., & Li, L. (2016, November). Using LSTM and GRU neural network methods for traffic flow prediction. In *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)* (pp. 324-328). IEEE. Wuhan, China. <https://doi.org/10.1109/YAC.2016.7804912>
- Fukuda, K., Yamanobe, N., Ramirez-Alpizar, I. G., & Harada, K. (2020, January). Assembly motion recognition framework using only images. In *2020 IEEE/SICE International Symposium on System Integration (SII)* (pp. 1242-1247). IEEE. USA. <https://doi.org/10.1109/SII46433.2020.9026247>
- Furugi, A., & Haliloğlu, M. (2022). A mathematical model for line-seru conversion and scheduling problem in seru production system. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37(3), 1213-1223. <https://doi.org/10.17341/gazimmfd.884293>
- Gai, Y., Yin, Y., Tang, J., & Liu, S. (2022). Minimizing makespan of a production batch within concurrent systems: seru production perspective. *Journal of Management Science and Engineering*, 7(1), 1-18. <https://doi.org/10.1016/j.jmse.2020.10.002>
- Ganegedara, T. (2022). *Natural Language Processing with TensorFlow: Teach language to machines using Python's deep learning library* (2nd ed.). Packt Publishing Ltd.
- Gao, W., Zhang, L., Huang, W., Min, F., He, J., & Song, A. (2021). Deep neural networks for sensor-based human activity recognition using selective kernel convolution. *IEEE Transactions on Instrumentation and Measurement*, 70, 1-13. <https://doi.org/10.1109/TIM.2021.3102735>

- Ghazal, S., Khan, U. S., Mubasher Saleem, M., Rashid, N., & Iqbal, J. (2019). Human activity recognition using 2D skeleton data and supervised machine learning. *IET Image Processing*, 13(13), 2572-2578. <https://doi.org/10.1049/iet-ipr.2019.0030>
- Giuliano, I., & Taurino, T. (2014, 6-8, October). Augmented-Reality Application for a Seru-type Manufacturing as Lean as Possible. Camarinha-Matos, L.M., Afsarmanesh, H. (Ed.) In *Collaborative Systems for Smart Networked Environments. PRO-VE 2014. IFIP Advances in Information and Communication Technology*, vol 434. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-662-44745-1_46
- Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: an overview. *arXiv preprint arXiv:2008.05756*. <https://doi.org/10.48550/arXiv.2008.05756>
- Grishchenko I. ve Bazarevsky V. (2020). MediaPipe Holistic — Simultaneous Face, Hand and Pose Prediction, on Device. <https://ai.googleblog.com/2020/12/MediaPipe-holistic-simultaneous-face.html>.
- Gu, Y., Liu, M., Sheng, W., Ou, Y., & Li, Y. (2021). Sensor fusion based manipulative action recognition. *Autonomous Robots*, 45, 1-13. <https://doi.org/10.1007/s10514-020-09943-8>
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27-48. <https://doi.org/10.1016/j.neucom.2015.09.116>
- Gupta, A., Gupta, K., Gupta, K., & Gupta, K. (2021, February). Human Activity Recognition Using Pose Estimation and Machine Learning Algorithm. In *ISIC* (Vol. 21, pp. 25-27). India.
- Günther, L. C., Kärcher, S., & Bauernhansl, T. (2019). Activity recognition in manual manufacturing: Detecting screwing processes from sensor data. *Procedia CIRP*, 81, 1177-1182. <https://doi.org/10.1016/j.procir.2019.03.288>
- Hackeling, G. (2017). *Mastering Machine Learning with scikit-learn*. Packt Publishing Ltd.
- Haliloğlu, M. (2021). *Seru Üretim Sisteminde Hat-Seru Dönüşümü ve Çizelgeleme Probleminin Matematiksel Modellenmesi* [Yüksek Lisans Tezi] Ondokuz Mayıs Üniversitesi
- Han, D., Lee, C., & Kang, H. (2021). Gravity Control-Based Data Augmentation Technique for Improving VR User Activity Recognition. *Symmetry*, 13(5), 845. <https://doi.org/10.3390/sym13050845>
- Hegelich, S. (2017). Deep learning and punctuated equilibrium theory. *Cognitive Systems Research*, 45, 59-69. <https://doi.org/10.1016/j.cogsys.2017.02.006>
- Hernandez, J., Valarezo, G., Cobos, R., Kim, J. W., Palacios, R., & Abad, A. G. (2021). Hierarchical Human Action Recognition to Measure the Performance of Manual Labor. *IEEE Access*, 9, 103110-103119. <https://doi.org/10.1109/ACCESS.2021.3095934>

- Hirawat, A., Taterh, S., & Sharma, T. K. (2022). A dynamic window-size based segmentation technique to detect driver entry and exit from a car. *Journal of King Saud University-Computer and Information Sciences*, 34(10), 8514-8522. <https://doi.org/10.1016/j.jksuci.2021.08.028>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hoelzemann, A., Sorathiya, N., & Van Laerhoven, K. (2021, March). Data augmentation strategies for human activity data using generative adversarial neural networks. In *2021 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)* (pp. 8-13). IEEE. Germany. <https://doi.org/10.1109/PerComWorkshops51409.2021.9431046>
- Hossin, M., & Sulaiman, M. N. (2015). A review on evaluation metrics for data classification evaluations. *International journal of data mining & knowledge management process*, 5(2), 1-11.
- Huan, R., Zhan, Z., Ge, L., Chi, K., Chen, P., & Liang, R. (2021). A hybrid CNN and BLSTM network for human complex activity recognition with multi-feature fusion. *Multimedia Tools and Applications*, 80(30), 36159-36182. <https://doi.org/10.1007/s11042-021-11363-4>
- Huang, H., & Lin, S. (2018, October). WiDet: Wi-Fi based device-free passive person detection with deep convolutional neural networks. In *Proceedings of the 21st ACM International Conference on Modeling, Analysis and Simulation of Wireless and Mobile Systems* (pp. 53-60). <https://doi.org/10.1145/3242102.3242119>
- Huang, H. W., Fadli, M., Nugraha, A. K., Lin, C. W., & Cheng, R. G. (2022, November). AI DJ System for Electronic Dance Music. In *2022 International Symposium on Electronics and Smart Devices (ISESD)* (pp. 1-6). IEEE. Indonesia. <https://doi.org/10.1109/ISESD56103.2022.9980591>
- Huang, K., Shi, Y., Zhao, F., Zhang, Z., & Tu, S. (2020). Multiple instance deep learning for weakly-supervised visual object tracking. *Signal Processing: Image Communication*, 84, 1-6. <https://doi.org/10.1016/j.image.2020.115807>
- Huikari, V., Koskimäki, H., Siirtola, P., & Rönning, J. (2010, December). User-independent activity recognition for industrial assembly lines-feature vs. instance selection. In *5th International Conference on Pervasive Computing and Applications* (pp. 307-312). IEEE. Slovenia. <https://doi.org/10.1109/ICPCA.2010.5704118>
- Issa, M. E., Helmi, A. M., Al-Qaness, M. A., Dahou, A., Elaziz, M. A., & Damaševičius, R. (2022). Human Activity Recognition Based on Embedded Sensor Data Fusion for the Internet of Healthcare Things. In *Healthcare* 10(6), 1-16. Multidisciplinary Digital Publishing Institute. <https://doi.org/10.3390/healthcare10061084>
- Iwana, B. K., & Uchida, S. (2021a, January). Time series data augmentation for neural networks by time warping with a discriminative teacher. In *2020 25th International Conference on Pattern Recognition (ICPR)* (pp. 3558-3565). IEEE. Italy. <https://doi.org/10.1109/ICPR48806.2021.9412812>

- Iwana, B. K., & Uchida, S. (2021b). An empirical survey of data augmentation for time series classification with neural networks. *Plos one*, 16(7), 1-32. <https://doi.org/10.1371/journal.pone.0254841>
- Iyer, S. J., Saranya, P., & Sivaram, M. (2021, January). Human Pose-Estimation and low-cost Interpolation for Text to Indian Sign Language. In 2021 11th International Conference on Cloud Computing, Data Science & Engineering (Confluence) (pp. 130-135). IEEE.
- Jadidi, M., Di Liddo, L., & Dworkin, S. B. (2021). A long short-term memory neural network for the low-cost prediction of soot concentration in a time-dependent flame. *Energies*, 14(5), 1394. <https://doi.org/10.3390/en14051394>
- Jagdale, K. N., Patil, S. A., & Parchandekar, S. K. (2015). A Smart Manufacturing Execution System. *IOSR Journal of Electrical and Electronics Engineering*, 10(3), 14-28. doi: 10.9790/1676-10331428
- Jeong, C. Y., Shin, H. C., & Kim, M. (2021). Sensor-data augmentation for human activity recognition with time-warping and data masking. *Multimedia Tools and Applications*, 80(14), 20991-21009. <https://doi.org/10.1007/s11042-021-10600-0>
- Ji, S., Xu, W., Yang, M., & Yu, K. (2012). 3D convolutional neural networks for human action recognition. *IEEE transactions on pattern analysis and machine intelligence*, 35(1), 221-231. <https://doi.org/10.1109/TPAMI.2012.59>
- Jiang, Q., Liu, M., Wang, X., Ge, M., & Lin, L. (2016). Human motion segmentation and recognition using machine vision for mechanical assembly operation. *SpringerPlus*, 5, 1-18. <https://doi.org/10.1186/s40064-016-3279-x>
- Kaku, I. (2017). Is seru a sustainable manufacturing system?. *Procedia Manufacturing*, 8, 723-730. <https://doi.org/10.1016/j.promfg.2017.02.093>
- Kaku, I., Gong, J., Tang, J., & Yin, Y. (2008a). A mathematical model for converting conveyor assembly line to cellular manufacturing. *Industrial Engineering and Management Systems*, 7(2), 160-170.
- Kaku, I., Murase, Y., & Yin, Y. (2008b). A study on human-task-related performances in converting conveyor assembly line to cellular manufacturing. *European Journal of Industrial Engineering*, 2(1), 17-34. <https://doi.org/10.1504/EJIE.2008.016327>
- Kaku, I., Gong, J., Tang, J., & Yin, Y. (2009). Modeling and numerical analysis of line-cell conversion problems. *International Journal of Production Research*, 47(8), 2055-2078. <https://doi.org/10.1080/00207540802275889>
- Karim, M. M., Doell, D., Lingard, R., Yin, Z., Leu, M. C., & Qin, R. (2019). A region-based deep learning algorithm for detecting and tracking objects in manufacturing plants. *Procedia Manufacturing*, 39, 168-177. <https://doi.org/10.1016/j.promfg.2020.01.289>
- Keras Documentation. (2019). LSTM layer. https://keras.io/api/layers/recurrent_layers/lstm/ adresinden 11 Şubat 2023 tarihinde alınmıştır.
- Kerner, H., Campbell, J., & Strickland, M. (2022). Introduction to machine learning. In *Machine Learning for Planetary Science* (pp. 1-24). Elsevier.

- Khan, I. U., Afzal, S., & Lee, J. W. (2022). Human activity recognition via hybrid deep learning based model. *Sensors*, 22(1), 1-16. <https://doi.org/10.3390/s22010323>
- Khan, M. R. (2017). *Designing Cost Effective and Flexible Vinyl Windows Supply Chain: Assembly Line Design Using CM/SERU Concepts and Simultaneous Selection of Facilities and Suppliers* [Doktora Tezi] Ohio University
- Kina, C., Turk, K., Atalay, E., Donmez, I., & Tanyildizi, H. (2021). Comparison of extreme learning machine and deep learning model in the estimation of the fresh properties of hybrid fiber-reinforced SCC. *Neural Computing and Applications*, 33, 11641-11659. <https://doi.org/10.1007/s00521-021-05836-8>
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980. <https://doi.org/10.48550/arXiv.1412.6980>
- Knisley, J. N. (2021). *Optimal Skill Levels for Seru Versus Assembly Line with Augmented Reality Training Considerations* [Yüksek Lisans Tezi] Ohio University
- Knoch, S., Herbig, N., Ponpathirkoottam, S., Kosmalla, F., Staudt, P., Porta, D., Fettke, P., & Loos, P. (2020). Sensor-based human-process interaction in discrete manufacturing. *Journal on Data Semantics*, 9, 21-37. <https://doi.org/10.1007/s13740-019-00109-z>
- Kobayashi, T., Aoki, Y., Shimizu, S., Kusano, K., & Okumura, S. (2019, November). Fine-grained action recognition in assembly work scenes by drawing attention to the hands. In *2019 15th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)* (pp. 440-446). IEEE. Italy. <https://doi.org/10.1109/SITIS.2019.00077>
- Korstanje, J. (2022). *Machine Learning on Geographical Data Using Python: Introduction into Geodata with Applications and Use Cases*. Apress.
- Koskimaki, H., Huikari, V., Siirtola, P., Laurinen, P., & Roning, J. (2009, June). Activity recognition using a wrist-worn inertial measurement unit: A case study for industrial assembly lines. In *2009 17th mediterranean conference on control and automation* (pp. 401-405). IEEE. Greece. <https://doi.org/10.1109/MED.2009.5164574>
- Kozina, S., Lustrek, M., & Gams, M. (2011, July). Dynamic signal segmentation for activity recognition. In *Proceedings of International Joint Conference on Artificial Intelligence, Barcelona, Spain* (Vol. 1622, p. 1522).
- Kraus, M., & Feuerriegel, S. (2017). Decision support from financial disclosures with deep neural networks and transfer learning. *Decision Support Systems*, 104, 38-48. <https://doi.org/10.1016/j.dss.2017.10.001>
- Kurushima, K. 2017. Basic Information about Seru Production Method. Tech Note [in Japanese]. <https://www.ipros.jp/technote/basic-cell-production/> adresinden 29 Şubat 2020 tarihinde alınmıştır.
- Kühnert, C., Gonuguntla, N. M., Krieg, H., Nowak, D., & Thomas, J. A. (2021). Application of LSTM networks for water demand prediction in optimal pump control. *Water*, 13(5), 644. <https://doi.org/10.3390/w13050644>
- Labrador, M. A., & Yejas, O. D. L. (2013). *Human activity recognition: Using wearable sensors and smartphones*. CRC Press.

- Lakhal, A., Sejri, N., Chaabouni, Y., Jaafar, F., & Cheikhrouhou, M. (2017). Ergonomic analysis in a company of clothing and evaluation of an ergonomic index related to Msds. *International Journal of Research and Reviews in Applied Sciences*, 31(2), 46-53.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436-444. <https://doi.org/10.1038/nature14539>
- Le Guennec, A., Malinowski, S., & Tavenard, R. (2016, September). Data augmentation for time series classification using convolutional neural networks. In *ECML/PKDD workshop on advanced analytics and learning on temporal data*.
- Leng, J., Chen, Q., Mao, N., & Jiang, P. (2018). Combining granular computing technique with deep learning for service planning under social manufacturing contexts. *Knowledge-Based Systems*, 143, 295-306. <https://doi.org/10.1016/j.knosys.2017.07.023>
- Li, J. H., Tian, L., Wang, H., An, Y., Wang, K., & Yu, L. (2019). Segmentation and recognition of basic and transitional activities for continuous physical human activity. *IEEE access*, 7, 42565-42576. <https://doi.org/10.1109/ACCESS.2019.2905575>
- Li, W., Wu, H., Zhu, N., Jiang, Y., Tan, J., & Guo, Y. (2021). Prediction of dissolved oxygen in a fishery pond based on gated recurrent unit (GRU). *Information Processing in Agriculture*, 8(1), 185-193. <https://doi.org/10.1016/j.inpa.2020.02.002>
- Li, X., Li, D., Wu, X., Zheng, H., & Yin, Y. (2017, June). A cooperative co-evolution approach for a line-seru conversion problem. In *2017 IEEE Congress on Evolutionary Computation (CEC)* (pp. 1406-1411). IEEE. Spain. <https://doi.org/10.1109/CEC.2017.7969468>
- Li, X., Yu, Y., & Huang, M. (2022). Multi-objective cooperative coevolution algorithm with a Master-Slave mechanism for Seru Production. *Applied Soft Computing*, 119, 1-15. <https://doi.org/10.1016/j.asoc.2022.108593>
- Lian, J., Liu, C., Li, W., & Yin, Y. (2018). A multi-skilled worker assignment problem in seru production systems considering the worker heterogeneity. *Computers & Industrial Engineering*, 118, 366-382. <https://doi.org/10.1016/j.cie.2018.02.035>
- Lindholm, A., Wahlström, N., Lindsten, F., & Schön, T. B. (2022). *Machine Learning: A First Course for Engineers and Scientists*. Cambridge University Press.
- Liu, C., Dang, F., Li, W., Lian, J., Evans, S., & Yin, Y. (2015). Production planning of multi-stage multi-option seru production systems with sustainable measures. *Journal of Cleaner Production*, 105, 285-299. <https://doi.org/10.1016/j.jclepro.2014.03.033>
- Liu, C., Li, W., Lian, J., & Yin, Y. (2012). Reconfiguration of assembly systems: From conveyor assembly line to serus. *Journal of Manufacturing Systems*, 31(3), 312-325. <https://doi.org/10.1016/j.jmsy.2012.02.003>
- Liu, C., Lian, J., Yin, Y., & Li, W. (2010). Seru Seisan-an innovation of the production management Mode in - Japan. *Asian Journal of Technology Innovation*, 18(2), 89-113. <https://doi.org/10.1080/19761597.2010.9668694>

- Liu, C., Stecke, K. E., Lian, J., & Yin, Y. (2014). An implementation framework for seru production. *International Transactions in Operational Research*, 21(1), 1-19. <https://doi.org/10.1111/itor.12014>
- Liu, C., Yang, N., Li, W., Lian, J., Evans, S., & Yin, Y. (2013). Training and assignment of multi-skilled workers for implementing seru production systems. *The International Journal of Advanced Manufacturing Technology*, 69, 937-959. <https://doi.org/10.1007/s00170-013-5027-5>
- Liu, F., Fang, K., Tang, J., & Yin, Y. (2022). Solving the rotating seru production problem with dynamic multi-objective evolutionary algorithms. *Journal of Management Science and Engineering*, 7(1), 48-66. <https://doi.org/10.1016/j.jmse.2021.05.004>
- Liu, D., Sepulveda, N., & Zheng, M. (2018b). Artificial neural networks condensation: A strategy to facilitate adaption of machine learning in medical settings by reducing computational burden. *arXiv preprint arXiv:1812.09659*. <https://doi.org/10.48550/arXiv.1812.09659>
- Liu, H., & Lang, B. (2019). Machine learning and deep learning methods for intrusion detection systems: A survey. *Applied Sciences*, 9(20), 1-28. <https://doi.org/10.3390/app9204396>
- Liu, L., Liu, Y., & Zhang, J. (2018a). Learning-based hand motion capture and understanding in assembly process. *IEEE Transactions on Industrial Electronics*, 66(12), 9703-9712. <https://doi.org/10.1109/TIE.2018.2884206>
- Lore, K. G., Stoecklein, D., Davies, M., Ganapathysubramanian, B., & Sarkar, S. (2018). A deep learning framework for causal shape transformation. *Neural Networks*, 98, 305-317. <https://doi.org/10.1016/j.neunet.2017.12.003>
- Lou, P., Li, J., Zeng, Y., Chen, B., & Zhang, X. (2022). Real-time monitoring for manual operations with machine vision in smart manufacturing. *Journal of Manufacturing Systems*, 65, 709-719. <https://doi.org/10.1016/j.jmsy.2022.10.015>
- Luo, L., Zhang, Z., & Yin, Y. (2016, December). Seru loading with worker-operation assignment in single period. In *2016 IEEE international conference on industrial engineering and engineering management (IEEM)* (pp. 1055-1058). IEEE. Indonesia. <https://doi.org/10.1109/IEEM.2016.7798039>
- Lu, L., Zhang, C., Cao, K., Deng, T., & Yang, Q. (2022). A Multichannel CNN-GRU Model for Human Activity Recognition. *IEEE Access*, 10, 66797-66810. <https://doi.org/10.1109/ACCESS.2022.3185112>
- Luo, L., Zhang, Z., & Yin, Y. (2017). Modelling and numerical analysis of seru loading problem under uncertainty. *European Journal of Industrial Engineering*, 11(2), 185-204. <https://doi.org/10.1504/EJIE.2017.083255>
- Luo, L., Zhang, Z., & Yin, Y. (2021). Simulated annealing and genetic algorithm based method for a bi-level seru loading problem with worker assignment in seru production systems. *Journal of Industrial and Management Optimization*, 17(2), 779-803. <https://doi.org/10.3934/jimo.2019134>
- Luwe, Y. J., Lee, C. P., & Lim, K. M. (2022, July). Wearable Sensor-Based Human Activity Recognition with Hybrid Deep Learning Model. *Informatics*, 9(3). <https://doi.org/10.3390/informatics9030056>

- Ma, H., Li, W., Zhang, X., Gao, S., & Lu, S. (2019, August). AttnSense: Multi-level attention mechanism for multimodal human activity recognition. S. Kraus (Ed.), In *IJCAI* (pp. 3109-3115). Macao, China.
- Ma, W., Wu, Y., Cen, F., & Wang, G. (2020). Mdfn: Multi-scale deep feature learning network for object detection. *Pattern Recognition*, 100, 1-13. <https://doi.org/10.1016/j.patcog.2019.107149>
- Maekawa, T., Nakai, D., Ohara, K., & Namioka, Y. (2016, September). Toward practical factory activity recognition: unsupervised understanding of repetitive assembly work in a factory. In *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing* (pp. 1088-1099). <https://doi.org/10.1145/2971648.2971721>
- Mahmud, S., Tonmoy, M. T. H., Bhaumik, K. K., Rahman, A. K. M. M., Amin, M. A., Shoyaib, M., Khan, M. A. H., & Ali, A. A. (2020). Human activity recognition from wearable sensor data using self-attention. *arXiv preprint arXiv:2003.09018*. <https://doi.org/10.48550/arXiv.2003.09018>
- Male, J., & Martinez-Hernandez, U. (2021, March). Recognition of human activity and the state of an assembly task using vision and inertial sensor fusion methods. In *2021 22nd IEEE International Conference on Industrial Technology (ICIT)* (Vol. 1, pp. 919-924). IEEE. Spain. <https://doi.org/10.1109/ICIT46573.2021.9453672>
- Manupati, V. K., Deepthi, T. V., Ramakotaiah, K., & Rao, S. S. (2015, March). Reconfiguration of networked seru production systems in an Indian Perspective. In *2015 International Conference on Industrial Engineering and Operations Management (IEOM)* (pp. 1-7). IEEE. Dubai, United Arab Emirates. <https://doi.org/10.1109/IEOM.2015.7093755>
- MARIN, F. B., GURĂU, G., & MARIN, M. (2022). Real-Time Assembly Operation Recognition. *The Annals of "Dunarea de Jos" University of Galati. Fascicle IX, Metallurgy and Materials Science*, 45(4), 92-95. <https://doi.org/10.35219/mms.2022.4.15>
- Martín, A., Lara-Cabrera, R., Fuentes-Hurtado, F., Naranjo, V., & Camacho, D. (2018). Evodeep: a new evolutionary approach for automatic deep neural networks parametrisation. *Journal of Parallel and Distributed Computing*, 117, 180-191. <https://doi.org/10.1016/j.jpdc.2017.09.006>
- Maruthi, P. B., Prasad, S., & Tyagi, A. K. (2024). *Machine Learning Algorithms Using Scikit and TensorFlow Environments*. IGI Global
- MediaPipe Github, (2019). <https://google.github.io/MediaPipe/solutions/hands>. adresinden 10 Aralık 2022 tarihinde alınmıştır.
- MediaPipe Github, (2020): <https://google.github.io/MediaPipe/solutions/pose.html>. adresinden 10 Aralık 2022 tarihinde alınmıştır.
- Mehmood, A., Iqbal, M., Mehmood, Z., Irtaza, A., Nawaz, M., Nazir, T., & Masood, M. (2021). Prediction of heart disease using deep convolutional neural networks. *Arabian Journal for Science and Engineering*, 46(4), 3409-3422

- Mekruksavanich, S., & Jitpattanakul, A. (2022). RNN-based deep learning for physical activity recognition using smartwatch sensors: A case study of simple and complex activity recognition. *Mathematical Biosciences and Engineering*, 19(6), 5671-5698. <https://doi.org/10.3934/mbe.2022265>
- Mhalla, A., Chateau, T., & Amara, N. E. B. (2019). Spatio-temporal object detection by deep learning: Video-interlacing to improve multi-object tracking. *Image and Vision Computing*, 88, 120-131. <https://doi.org/10.1016/j.imavis.2019.03.002>
- Miao, Q., Bai, Z., Liu, X., & Awais, M. (2022). Modelling and numerical analysis for seru system balancing with lot splitting. *International Journal of Production Research*, 1-24. <https://doi.org/10.1080/00207543.2022.2149873>
- Millar, C., Siddique, N., & Kerr, E. (2020, September). LSTM classification of sEMG signals for individual finger movements using low cost wearable sensor. In *2020 International Symposium on Community-centric Systems (CcS)* (pp. 1-8). IEEE. Tokyo, Japan. <https://doi.org/10.1109/CcS49175.2020.9231515>
- Mirtaheeri, S. L., & Shahbazian, R. (2022). *Machine Learning: Theory to Applications*. CRC Press.
- Moews, B., Herrmann, J. M., & Ibikunle, G. (2019). Lagged correlation-based deep learning for directional trend change prediction in financial time series. *Expert Systems with Applications*, 120, 197-206. <https://doi.org/10.1016/j.eswa.2018.11.027>
- Mohsen, H., El-Dahshan, E. S. A., El-Horbaty, E. S. M., & Salem, A. B. M. (2018). Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3(1), 68-71. <https://doi.org/10.1016/j.fcij.2017.12.001>
- Moryossef, A., Tsochantaridis, I., Dinn, J., Camgoz, N. C., Bowden, R., Jiang, T., Rios, A., Müller, M. & Ebling, S. (2021). Evaluating the immediate applicability of pose estimation for sign language recognition. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 3434-3440).
- Mutegeki, R., & Han, D. S. (2020, February). A CNN-LSTM approach to human activity recognition. In *2020 international conference on artificial intelligence in information and communication (ICAIIIC)* (pp. 362-366). IEEE. Fukuoka, Japan. <https://doi.org/10.1109/ICAIIIC48513.2020.9065078>
- Nafea, O., Abdul, W., & Muhammad, G. (2022). Multi-sensor human activity recognition using CNN and GRU. *International Journal of Multimedia Information Retrieval*, 11(2), 135-147. <https://doi.org/10.1007/s13735-022-00234-9>
- Nath, N. D. (2017). *Construction ergonomic risk and productivity assessment using mobile technology and machine learning* [Yüksek Lisans Tezi] Missouri State University
- Nishanth, R., Muthukumar, M. V., & Arivanantham, A. (2015). Ergonomic workplace evaluation for assessing occupational risks in multistage pump assembly. *International Journal of Computer Applications*, 113(9), 9-13. <https://doi.org/10.5120/19852-1764>

- Nunez, J. C., Cabido, R., Pantrigo, J. J., Montemayor, A. S., & Velez, J. F. (2018). Convolutional neural networks and long short-term memory for skeleton-based human activity and hand gesture recognition. *Pattern Recognition*, 76, 80-94. <https://doi.org/10.1016/j.patcog.2017.10.033>
- Odhiambo, C. O., Saha, S., Martin, C. K., & Valafar, H. (2022). Human Activity Recognition on Time Series Accelerometer Sensor Data using LSTM Recurrent Neural Networks. *arXiv preprint arXiv:2206.07654*. <https://doi.org/10.48550/arXiv.2206.07654>
- Oh, C., Han, S., & Jeong, J. (2020). Time-series data augmentation based on interpolation. *Procedia Computer Science*, 175, 64-71. <https://doi.org/10.1016/j.procs.2020.07.012>
- Oishi, A., & Yagawa, G. (2017). Computational mechanics enhanced by deep learning. *Computer Methods in Applied Mechanics and Engineering*, 327, 327-351. <https://doi.org/10.1016/j.cma.2017.08.040>
- Oluwalade, B., Neela, S., Wawira, J., Adejumo, T., & Purkayastha, S. (2021). Human activity recognition using deep learning models on smartphones and smartwatches sensor data. *arXiv preprint arXiv:2103.03836*. <https://doi.org/10.48550/arXiv.2103.03836>
- Ordóñez, F. J., & Roggen, D. (2016). Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition. *Sensors*, 16(1), 1-25. <https://doi.org/10.3390/s16010115>
- Ortiz, J. L. R. (2014). *Smartphone-based human activity recognition*. Springer. <https://doi.org/10.1007/978-3-319-14274-6>
- Owen, L. (2022). *Hyperparameter Tuning with Python: Boost Your Machine Learning Model's Performance Via Hyperparameter Tuning*. Packt Publishing Limited.
- Pajankar, A., & Joshi, A. (2022). *Hands-on Machine Learning with Python: Implement Neural Network Solutions with Scikit-learn and PyTorch*. Apress.
- Pérez-Hernández, F., Tabik, S., Lamas, A., Olmos, R., Fujita, H., & Herrera, F. (2020). Object detection binary classifiers methodology based on deep learning to identify small objects handled similarly: Application in video surveillance. *Knowledge-Based Systems*, 194, 1-10. <https://doi.org/10.1016/j.knosys.2020.105590>
- Pi, Y., Nath, N. D., & Behzadan, A. H. (2020). Convolutional neural networks for object detection in aerial imagery for disaster response and recovery. *Advanced Engineering Informatics*, 43, 1-14. <https://doi.org/10.1016/j.aei.2019.101009>
- Pimminger, S., Kurschl, W., Augstein, M., Altmann, J., & Heinzlreiter, J. (2019, June). Low-cost tracking of assembly tasks in industrial environments. In *Proceedings of the 12th ACM International Conference on Pervasive Technologies Related to Assistive Environments* (pp. 86-93). <https://doi.org/10.1145/3316782.3321526>
- Prabhu, V. G., Taaffe, K., & Pirrallo, R. (2021). A multi-layered LSTM for predicting physician stress during an ED shift. PREPRINT (Version 1) available at *Research Square*. <https://doi.org/10.21203/rs.3.rs-318589/v1>

- Prakash, J., Yang, C. C., & Chin, J. F. (2017). Labour-intensive line-cell reconfiguration with cycle time adjustment attributed to changes in situational awareness. *International Journal of Industrial and Systems Engineering*, 27(2), 210-232. <https://doi.org/10.1504/IJISE.2017.086268>
- Preece, S. J., Goulermas, J. Y., Kenney, L. P., & Howard, D. (2008). A comparison of feature extraction methods for the classification of dynamic activities from accelerometer data. *IEEE Transactions on Biomedical Engineering*, 56(3), 871-879. <https://doi.org/10.1109/TBME.2008.2006190>
- Pushpalatha, S., & Math, S. (2022). Hybrid deep learning framework for human activity recognition. *International Journal of Nonlinear Analysis and Applications*, 13(1), 1225-1237. <https://doi.org/10.22075/IJNAA.2022.5673>
- Ramachandra, S., Hoelzemann, A., & Van Laerhoven, K. (2021). Transformer Networks for Data Augmentation of Human Physical Activity Recognition. *arXiv preprint arXiv:2109.01081*. <https://doi.org/10.48550/arXiv.2109.01081>
- Ravi, D., Wong, C., Lo, B., & Yang, G. Z. (2016, June). Deep learning for human activity recognition: A resource efficient implementation on low-power devices. In *2016 IEEE 13th international conference on wearable and implantable body sensor networks (BSN)* (pp. 71-76). IEEE. San Francisco, CA, USA. <https://doi.org/10.1109/BSN.2016.7516235>
- Reiss, A., & Stricker, D. (2012, June). Introducing a new benchmarked dataset for activity monitoring. In *2012 16th international symposium on wearable computers* (pp. 108-109). IEEE. Newcastle, UK. <https://doi.org/10.1109/ISWC.2012.13>
- Riedel, A., Brehm, N., & Pfeifroth, T. (2022). Hand gesture recognition of methods-time measurement-1 motions in manual assembly tasks using graph convolutional networks. *Applied Artificial Intelligence*, 36(1), 1281-1303. <https://doi.org/10.1080/08839514.2021.2014191>
- Rocha, C. N., & Rodrigues, F. (2021). Forecasting emergency department admissions. *Intelligent Data Analysis*, 25(6), 1579-1601. <https://doi.org/10.3233/IDA-205390>
- Rodrigues, F., Markou, I., & Pereira, F. C. (2019). Combining time-series and textual data for taxi demand prediction in event areas: A deep learning approach. *Information Fusion*, 49, 120-129. <https://doi.org/10.1016/j.inffus.2018.07.007>
- Ronao, C. A., & Cho, S. B. (2016). Human activity recognition with smartphone sensors using deep learning neural networks. *Expert systems with applications*, 59, 235-244. <https://doi.org/10.1016/j.eswa.2016.04.032>
- Rückert, P., Papenberg, B., & Tracht, K. (2021). Classification of assembly operations using machine learning algorithms based on visual sensor data. *Procedia CIRP*, 97, 110-116. <https://doi.org/10.1016/j.procir.2020.05.211>
- Shalaby, E., ElShennawy, N., & Sarhan, A. (2022). Utilizing deep learning models in CSI-based human activity recognition. *Neural Computing and Applications*, 34(8), 5993-6010. <https://doi.org/10.1007/s00521-021-06787-w>
- Shan, H., Qin, M., Zou, C., Peng, P., & Meng, Z. (2022). Assembly line-Seru conversion in the C2M enterprise: an empirical study in China. *Assembly Automation*, 42(4), 506-520. <https://doi.org/10.1108/AA-04-2022-0087>

- Shao, L., Zhang, Z., & Yin, Y. (2016). A bi-objective combination optimisation model for line-seru conversion based on queuing theory. *International Journal of Manufacturing Research*, 11(4), 322-338. <https://doi.org/10.1504/IJMR.2016.082821>
- Shao, L., Zhang, Z., & Yin, Y. (2017). Production system performance improvement by assembly line-seru conversion. In *Proceedings of the Tenth International Conference on Management Science and Engineering Management* (pp. 1165-1180). Springer, Singapore. https://doi.org/10.1007/978-981-10-1837-4_95
- Sheppard, K., Gardin, J., Sabnis, G. S., Peer, A., Darrell, M., Deats, S., Geuther, B., Lutz, C. M., & Kumar, V. (2021). Gait-level analysis of mouse open field behavior using deep learning-based pose estimation. *BioRxiv*, 2020-12. <https://doi.org/10.1101/2020.12.29.424780>
- Shen, G., Tan, Q., Zhang, H., Zeng, P., & Xu, J. (2018). Deep learning with gated recurrent unit networks for financial sequence predictions. *Procedia computer science*, 131, 895-903. <https://doi.org/10.1016/j.procs.2018.04.298>
- Shi, H., Xu, M., Ma, Q., Zhang, C., Li, R., & Li, F. (2017). A whole system assessment of novel deep learning approach on short-term load forecasting. *Energy Procedia*, 142, 2791-2796. <https://doi.org/10.1016/j.egypro.2017.12.423>
- Siegel, N. G. (2019). *Engineering Project Management*. John Wiley & Sons.
- Silva, V., Soares, F., Leão, C. P., Esteves, J. S., & Vercelli, G. (2021). Skeleton driven action recognition using an image-based spatial-temporal representation and convolution neural network. *Sensors*, 21(13), 1-20. <https://doi.org/10.3390/s21134342>
- Singh, R., Dhillon, J. K., Kushwaha, A. K. S., & Srivastava, R. (2019). Depth based enlarged temporal dimension of 3D deep convolutional network for activity recognition. *Multimedia Tools and Applications*, 78, 30599-30614. <https://doi.org/10.1007/s11042-018-6425-3>
- Singh, A., & Chauhan, S. (2022). Intrusion Detection System Using Deep Learning Asymmetric Autoencoder (DLAA). In *Machine Learning, Blockchain, and Cyber Security in Smart Environments* (pp. 201-216). Chapman and Hall/CRC.
- Singh, S. (2017). A Study on Seru Production System. *International Journal of Applied Research in Science and Engineering*. 83-89. <http://www.ijarse.org/images/scripts/201719.pdf>
- Singh, T., & Vishwakarma, D. K. (2019). Human activity recognition in video benchmarks: A survey. In *Advances in Signal Processing and Communication: Select Proceedings of ICSC 2018* (pp. 247-259). Springer.
- Soh, P. W., Chang, J. W., & Huang, J. W. (2018). Adaptive deep learning-based air quality prediction model using the most relevant spatial-temporal relations. *Ieee Access*, 6, 38186-38199. <https://doi.org/10.1109/ACCESS.2018.2849820>
- Sopidis, G., Haslgrübler, M., Azadi, B., Anzengruber-Tánase, B., Ahmad, A., Ferscha, A., & Baresch, M. (2022, June). Micro-activity recognition in industrial assembly process with IMU data and deep learning. In *Proceedings of the 15th International Conference on Pervasive Technologies Related to Assistive Environments* (pp. 103-112). <https://doi.org/10.1145/3529190.3529204>

- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, *15*(1), 1929-1958.
- Stecke, K. E., Yin, Y., & Kaku, I. (2014). Seru production: an extension of just-in-time approach for volatile business environments. In *Analytical Approaches to Strategic Decision-Making: Interdisciplinary Considerations* (pp. 45-58). IGI Global.
- Stecke, K. E., Yin, Y., Kaku, I., & Murase, Y. (2012). Seru: the organizational extension of JIT for a super-talent factory. *International Journal of Strategic Decision Sciences (IJSDS)*, *3*(1), 106-119. <https://doi.org/10.4018/jsds.2012010104>
- Sujatha, K., Nalinashini, G., Ponmagal, R. S., Ganesan, A., Kalaivani, A., & Hari, R. (2022). Hybrid deep learning neuro-fuzzy networks for industrial parameters estimation. In *Artificial Intelligence and Machine Learning for EDGE Computing* (pp. 325-341). Academic Press.
- Sun, W., Li, Q., Huo, C., Yu, Y., & Ma, K. (2016). Formulations, features of solution space, and algorithms for line-pure seru system conversion. *Mathematical Problems in Engineering*. 2016, 1-14. <https://doi.org/10.1155/2016/9748378>
- Sun, W., Wu, Y., Lou, Q., & Yu, Y. (2019). A cooperative coevolution algorithm for the seru production with minimizing makespan. *IEEE Access*, *7*, 5662-5670. <https://doi.org/10.1109/ACCESS.2018.2889372>
- Sun, W., Yu, Y., Lou, Q., Wang, J., & Guan, Y. (2020). Reducing the total tardiness by Seru production: model, exact and cooperative coevolution solutions. *International Journal of Production Research*, *58*(21), 6441-6452. <https://doi.org/10.1080/00207543.2019.1680898>
- Tabata, M. 2017. What is the Seru Production Method? -Knows the Characteristics of the Seru Production and a Successful Introduction Mechanism-. Kaizen Base [in Japanese]. [https://www.kaizen-base.com/contents/kall-42930/adresinden-29 Şubat 2020 tarihinde alınmıştır.](https://www.kaizen-base.com/contents/kall-42930/adresinden-29-%c5%9cubat-2020-tarihinde-alınmıřtır)
- Tan, T. H., Wu, J. Y., Liu, S. H., & Gochoo, M. (2022). Human activity recognition using an ensemble learning algorithm with smartphone sensor data. *Electronics*, *11*(3), 1-17. <https://doi.org/10.3390/electronics11030322>
- Tao, W., Al-Amin, M., Chen, H., Leu, M. C., Yin, Z., & Qin, R. (2020b). Real-time assembly operation recognition with fog computing and transfer learning for human-centered intelligent manufacturing. *Procedia Manufacturing*, *48*, 926-931. <https://doi.org/10.1016/j.promfg.2020.05.131>
- Tao, W., Lai, Z. H., Leu, M. C., & Yin, Z. (2018). Worker activity recognition in smart manufacturing using IMU and sEMG signals with convolutional neural networks. *Procedia Manufacturing*, *26*, 1159-1166. <https://doi.org/10.1016/j.promfg.2018.07.152>
- Tao, W., Lai, Z. H., Leu, M. C., Yin, Z., & Qin, R. (2019). A self-aware and active-guiding training & assistant system for worker-centered intelligent manufacturing. *Manufacturing letters*, *21*, 45-49. <https://doi.org/10.1016/j.mfglet.2019.08.003>

- Tao, W., Leu, M. C., & Yin, Z. (2020a). Multi-modal recognition of worker activity for human-centered intelligent manufacturing. *Engineering Applications of Artificial Intelligence*, 95, 1-10. <https://doi.org/10.1016/j.engappai.2020.103868>
- Tharwat, A. (2021). Classification assessment methods. *Applied computing and informatics*, 17(1), 168-192. <https://doi.org/10.1016/j.aci.2018.08.003>
- Tian, Y., Su, D., Lauria, S., & Liu, X. (2022). Recent advances on loss functions in deep learning for computer vision. *Neurocomputing*, 497, 129-158
- Toshev, A., & Szegedy, C. (2014). Deeppose: Human pose estimation via deep neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1653-1660).
- Verma, U., Tyagi, P., & Kaur, M. (2022). Single Input Single Head CNN-GRU-LSTM Architecture for Recognition of Human Activities. *Indonesian Journal of Electrical Engineering and Informatics (IJEI)*, 10(2), 410-420. <https://doi.org/10.52549/ijeai.v10i2.3475>
- Villa, A., & Taurino, T. (2013). From JIT to Seru, for a Production as Lean as Possible. *Procedia Engineering*, 63, 956-965. <https://doi.org/10.1016/j.proeng.2013.08.172>
- Wan, S., Qi, L., Xu, X., Tong, C., & Gu, Z. (2020). Deep learning models for real-time human activity recognition with smartphones. *Mobile Networks and Applications*, 25(2), 743-755. <https://doi.org/10.1007/s11036-019-01445-x>
- Wang, C., & Jiang, P. (2019). Deep neural networks based order completion time prediction by using real-time job shop RFID data. *Journal of Intelligent Manufacturing*, 30, 1303-1318. <https://doi.org/10.1007/s10845-017-1325-3>
- Wang, J., Zhu, T., Gan, J., Chen, L. L., Ning, H., & Wan, Y. (2022c). Sensor data augmentation by resampling in contrastive learning for human activity recognition. *IEEE Sensors Journal*, 22(23), 22994-23008. <https://doi.org/10.1109/JSEN.2022.3214198>
- Wang, J., Chen, Y., Hao, S., Peng, X., & Hu, L. (2019c). Deep learning for sensor-based activity recognition: A survey. *Pattern recognition letters*, 119, 3-11. <https://doi.org/10.1016/j.patrec.2018.02.010>
- Wang, J., Liu, H., Qu, P., & Yin, Y. (2013, May). Design and operations of seru manufacturing: case study. In *The 6th PSU-UNS International Conference on Engineering and Technology (ICET-2013)* (pp. 15-17).
- Wang, J., Zhu, T., Chen, L., Ning, H., & Wan, Y. (2022a). Negative Selection by Clustering for Contrastive Learning in Human Activity Recognition. *arXiv preprint arXiv:2203.12230*.
- Wang, L., Zhang, Z., & Yin, Y. (2019a, December). Order acceptance and scheduling considering lot-spitting in seru production system. In *2019 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)* (pp. 1305-1309). IEEE, Macao, China. <https://doi.org/10.1109/IEEM44572.2019.8978529>

- Wang, S., Yu, S., Wang, H., Wu, D., Zhou, W., & Luo, H. (2022b, August). Research and Design of Human Behavior Recognition Method in Industrial Production Based on Depth Image. In *2022 4th International Conference on Industrial Artificial Intelligence (IAI)* (pp. 1-6). IEEE. Shenyang, China. <https://doi.org/10.1109/IAI55780.2022.9976693>
- Wang, Y., Liao, W., & Chang, Y. (2018a). Gated recurrent unit network-based short-term photovoltaic forecasting. *Energies*, 11(8), 2163. <https://doi.org/10.3390/en11082163>
- Wang, Y., & Tang, J. (2017, June). Multi-objective optimization model for seru production system formation under uncertain condition. In *2017 International Conference on Service Systems and Service Management* (pp. 1-6). IEEE. Dalian. <https://doi.org/10.1109/ICSSSM.2017.7996139>
- Wang, Y., & Tang, J. (2018). Cost and service-level-based model for a seru production system formation problem with uncertain demand. *Journal of Systems Science and Systems Engineering*, 27, 519-537. <https://doi.org/10.1007/s11518-018-5379-3>
- Wang, Z., Qin, R., Yan, J., & Guo, C. (2019b). Vision sensor based action recognition for improving efficiency and quality under the environment of industry 4.0. *Procedia CIRP*, 80, 711-716. <https://doi.org/10.1016/j.procir.2019.01.106>
- Wang, Y., Cang, S., & Yu, H. (2018b). A data fusion-based hybrid sensory system for older people's daily activity and daily routine recognition. *IEEE Sensors Journal*, 18(16), 6874-6888. <https://doi.org/10.1109/JSEN.2018.2833745>
- Ward, J. A., Lukowicz, P., Troster, G., & Starner, T. E. (2006). Activity recognition of assembly tasks using body-worn microphones and accelerometers. *IEEE transactions on pattern analysis and machine intelligence*, 28(10), 1553-1567. <https://doi.org/10.1109/TPAMI.2006.197>
- Wei, L., Ding, Y., Su, R., Tang, J., & Zou, Q. (2018). Prediction of human protein subcellular localization using deep learning. *Journal of Parallel and Distributed Computing*, 117, 212-217. <https://doi.org/10.1016/j.jpdc.2017.08.009>
- Wen, Q., Sun, L., Yang, F., Song, X., Gao, J., Wang, X., & Xu, H. (2020). Time series data augmentation for deep learning: A survey. *arXiv preprint arXiv:2002.12478*. <https://doi.org/10.48550/arXiv.2002.12478>
- Wu, L., Chan, F. T., Niu, B., & Li, L. (2018). Cross-trained worker assignment and comparative analysis on throughput of divisional and rotating seru. *Industrial Management & Data Systems*, 118(5), 1114-1136. <https://doi.org/10.1108/IMDS-07-2017-0303>
- Wu, S., Wang, Z., Shen, B., Wang, J. H., & Dongdong, L. (2020). Human-computer interaction based on machine vision of a smart assembly workbench. *Assembly Automation*, 40(3), 475-482. <https://doi.org/10.1108/AA-10-2018-0170>
- Wu, Y., Wang, L., & Chen, J. F. (2021a). A cooperative coevolution algorithm for complex hybrid seru-system scheduling optimization. *Complex & Intelligent Systems*, 7(5), 2559-2576. <https://doi.org/10.1007/s40747-021-00432-8>

- Wu, Y., Lin, Q., Yang, M., Liu, J., Tian, J., Kapil, D., & Vanderbloemen, L. (2021b, December). A computer vision-based yoga pose grading approach using contrastive skeleton feature representations. *Healthcare*, 10, 36. <https://doi.org/10.3390/healthcare10010036>
- Wu, Y., Zheng, B., & Zhao, Y. (2018, November). Dynamic gesture recognition based on LSTM-CNN. In *2018 Chinese Automation Congress (CAC)* (pp. 2446-2450). IEEE. Xi'an, China. <https://doi.org/10.1109/CAC.2018.8623035>
- Xia, K., Huang, J., & Wang, H. (2020). LSTM-CNN architecture for human activity recognition. *IEEE Access*, 8, 56855-56866. <https://doi.org/10.1109/ACCESS.2020.2982225>
- Xiao, C., Chen, N., Hu, C., Wang, K., Xu, Z., Cai, Y., Xu, L., Chen, Z., & Gong, J. (2019). A spatiotemporal deep learning model for sea surface temperature field prediction using time-series satellite data. *Environmental Modelling & Software*, 120, 1-20. <https://doi.org/10.1016/j.envsoft.2019.104502>
- Xu, C., Chai, D., He, J., Zhang, X., & Duan, S. (2019a). InnoHAR: A deep neural network for complex human activity recognition. *IEEE Access*, 7, 9893-9902. <https://doi.org/10.1109/ACCESS.2018.2890675>
- Xu, H., Chai, L., Luo, Z., & Li, S. (2022). Stock movement prediction via gated recurrent unit network based on reinforcement learning with incorporated attention mechanisms. *Neurocomputing*, 467, 214-228
- Xu, L., Geng, X., He, X., Li, J., & Yu, J. (2019b). Prediction in autism by deep learning short-time spontaneous hemodynamic fluctuations. *Frontiers in Neuroscience*, 13, 1-12. <https://doi.org/10.3389/fnins.2019.01120>
- Yadav, S. K., Tiwari, K., Pandey, H. M., & Akbar, S. A. (2022). Skeleton-based human activity recognition using ConvLSTM and guided feature learning. *Soft Computing* 26, 877-890. <https://doi.org/10.1007/s00500-021-06238-7>
- Yamazaki, K., Higashide, T., Tanaka, D., & Nagahama, K. (2018, December). Assembly manipulation understanding based on 3D object pose estimation and human motion estimation. In *2018 IEEE International Conference on Robotics and Biomimetics (ROBIO)* (pp. 802-807). IEEE. Kuala Lumpur, Malaysia. <https://doi.org/10.1109/ROBIO.2018.8665235>
- Yang, C. L., Li, W. T., & Hsu, S. C. (2020, August). Skeleton-based Hand Gesture Recognition for Assembly Line Operation. In *2020 International Conference on Advanced Robotics and Intelligent Systems (ARIS)* (pp. 1-6). IEEE. Taipei, Taiwan. <https://doi.org/10.1109/ARIS50834.2020.9205781>
- Yang, M., & Wang, J. (2022). Adaptability of financial time series prediction based on BiLSTM. *Procedia Computer Science*, 199, 18-25
- Yaşar, H., Çağıl, G., Torkul, O., & Şişçi, M. (2021). Cylinder pressure prediction of an HCCI engine using deep learning. *Chinese Journal of Mechanical Engineering*, 34(1), 7
- Yılmaz, Ö. F. (2019). Operational strategies for seru production system: a bi-objective optimisation model and solution methods. *International Journal of Production Research*, 58(11), 3195-3219. <https://doi.org/10.1080/00207543.2019.1669841>

- Yılmaz, Ö. F. (2020). Attaining flexibility in seru production system by means of Shojinka: An optimization model and solution approaches. *Computers & Operations Research*, 119, 104917. <https://doi.org/10.1016/j.cor.2020.104917>
- Yin, X., Fan, X., Zhu, W., & Liu, R. (2018b). Synchronous AR assembly assistance and monitoring system based on ego-centric vision. *Assembly Automation*, 39(1), 1-16. <https://doi.org/10.1108/AA-03-2017-032>
- Yin, X., Liu, Z., Liu, D., & Ren, X. (2022). A Novel CNN-based Bi-LSTM parallel model with attention mechanism for human activity recognition with noisy data. *Scientific Reports*, 12(1), 1-11. <https://doi.org/10.1038/s41598-022-11880-8>
- Yin, Y., Kaku, I., & Stecke, K. E. (2008). The evolution of seru production systems throughout Canon. In *SAGE Business Cases. Neilson Journals Publishing*. <https://doi.org/10.4135/9781526462060>
- Yin, Y., Stecke, K. E., & Li, D. (2018a). The evolution of production systems from Industry 2.0 through Industry 4.0. *International Journal of Production Research*, 56(1-2), 848-861. <https://doi.org/10.1080/00207543.2017.1403664>
- Yin, Y., Stecke, K. E., Swink, M., & Kaku, I. (2017). Lessons from seru production on manufacturing competitively in a high cost environment. *Journal of Operations Management*, 49, 67-76. <https://doi.org/10.1016/j.jom.2017.01.003>
- Ying, K. C., & Tsai, Y. J. (2017). Minimising total cost for training and assigning multiskilled workers in seru production systems. *International Journal of Production Research*, 55(10), 2978-2989. <https://doi.org/10.1080/00207543.2016.1277594>
- Yonemoto, H., Murasaki, K., Osawa, T., Sudo, K., Shimamura, J., & Taniguchi, Y. (2015, May). Egocentric articulated pose tracking for action recognition. In *2015 14th IAPR International Conference on Machine Vision Applications (MVA)* (pp. 98-101). IEEE. Tokyo, Japan. <https://doi.org/10.1109/MVA.2015.7153142>
- Yu, L., Zhou, R., Chen, R., & Lai, K. K. (2022). Missing data preprocessing in credit classification: One-hot encoding or imputation?. *Emerging Markets Finance and Trade*, 58(2), 472-482. <https://doi.org/10.1080/1540496X.2020.1825935>
- Yu, Y., Gong, J., Tang, J., Yin, Y., & Kaku, I. (2012). How to carry out assembly line-cell conversion? A discussion based on factor analysis of system performance improvements. *International Journal of Production Research*, 50(18), 5259-5280. <https://doi.org/10.1080/00207543.2012.693642>
- Yu, Y., Sun, W., Tang, J., & Wang, J. (2017). Line-hybrid seru system conversion: Models, complexities, properties, solutions and insights. *Computers & Industrial Engineering*, 103, 282-299. <https://doi.org/10.1016/j.cie.2016.11.035>
- Yu, Y., Sun, W., Tang, J., Kaku, I., & Wang, J. (2017). Line-seru conversion towards reducing worker (s) without increasing makespan: models, exact and meta-heuristic solutions. *International Journal of Production Research*, 55(10), 2990-3007. <https://doi.org/10.1080/00207543.2017.1284359>

- Yu, Y., & Tang, J. (2019). Review of seru production. *Frontiers of Engineering Management*, 6(2), 183-192. <https://doi.org/10.1007/s42524-019-0028-1>
- Yu, Y., Tang, J., Gong, J., Yin, Y., & Kaku, I. (2014). Mathematical analysis and solutions for multi-objective line-cell conversion problem. *European Journal of Operational Research*, 236(2), 774-786. <https://doi.org/10.1016/j.ejor.2014.01.029>
- Yu, Y., Tang, J., Sun, W., Yin, Y., & Kaku, I. (2013a). Reducing worker (s) by converting assembly line into a pure cell system. *International Journal of Production Economics*, 145(2), 799-806. <https://doi.org/10.1016/j.ijpe.2013.06.009>
- Yu, Y., Tang, J., Sun, W., Yin, Y., & Kaku, I. (2013b). Combining local search into non-dominated sorting for multi-objective line-cell conversion problem. *International Journal of Computer Integrated Manufacturing*, 26(4), 316-326. <https://doi.org/10.1080/0951192X.2012.717717>
- Yu, Y., Wang, S., Tang, J., Kaku, I., & Sun, W. (2016). Complexity of line-seru conversion for different scheduling rules and two improved exact algorithms for the multi-objective optimization. *SpringerPlus*, 5(1), 1-26. <https://doi.org/10.1186/s40064-016-2445-5>
- Zeng, S., Wu, Y., & Yu, Y. (2022). Multi-skilled worker assignment in seru production system for the trade-off between production efficiency and workload fairness. *Kybernetes*. <https://doi.org/10.1108/K-01-2022-0054>
- Zheng, C., Zhu, S., Mendieta, M., Yang, T., Chen, C., & Ding, Z. (2021). 3d human pose estimation with spatial and temporal transformers. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 11656-11665).
- Zhang, J., Wu, F., Wei, B., Zhang, Q., Huang, H., Shah, S. W., & Cheng, J. (2020c). Data augmentation and dense-LSTM for human activity recognition using WiFi signal. *IEEE Internet of Things Journal*, 8(6), 4628-4641. <https://doi.org/10.1109/JIOT.2020.3026732>
- Zhang, F., Bazarevsky, V., Vakunov, A., Tkachenka, A., Sung, G., Chang, C. L., & Grundmann, M. (2020b). MediaPipe hands: On-device real-time hand tracking. *arXiv preprint arXiv:2006.10214*. <https://doi.org/10.48550/arXiv.2006.10214>
- Zhang, H., Yan, X., & Li, H. (2018b). Ergonomic posture recognition using 3D view-invariant features from single ordinary camera. *Automation in Construction*, 94, 1-10. <https://doi.org/10.1016/j.autcon.2018.05.033>
- Zhang, Q., Yang, L. T., Chen, Z., & Li, P. (2018a). A survey on deep learning for big data. *Information Fusion*, 42, 146-157. <https://doi.org/10.1016/j.inffus.2017.10.006>
- Zhang, X., Liu, C., Li, W., Evans, S., & Yin, Y. (2017). Effects of key enabling technologies for seru production on sustainable performance. *Omega*, 66, 290-307. <https://doi.org/10.1016/j.omega.2016.01.013>
- Zhang, Y., Wang, L., Chen, H., Tian, A., Zhou, S., & Guo, Y. (2022c). IF-ConvTransformer: A framework for human activity recognition using IMU fusion and ConvTransformer. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 6(2), 1-26. <https://doi.org/10.1145/3534584>

- Zhang, Z., Gong, X., Song, X., Yin, Y., Lev, B., & Chen, J. (2022a). A column generation-based exact solution method for seru scheduling problems. *Omega*, 108, 1-10. <https://doi.org/10.1016/j.omega.2021.102581>
- Zhang, Z., Shao, L., & Yin, Y. (2020a). PSO-based algorithm for solving lot splitting in unbalanced seru production system. *International Journal of Industrial and Systems Engineering*, 35(4), 433-450. <https://doi.org/10.1504/IJISE.2020.108547>
- Zhang, Z., Song, X., Huang, H., Yin, Y., & Lev, B. (2022b). Scheduling problem in seru production system considering DeJong's learning effect and job splitting. *Annals of Operations Research*, 1-23. <https://doi.org/10.1007/s10479-021-04515-0>
- Zhao, S., Zhang, Y., Wang, S., Zhou, B., & Cheng, C. (2019). A recurrent neural network approach for remaining useful life prediction utilizing a novel trend features construction method. *Measurement*, 146, 279-288. <https://doi.org/10.1016/j.measurement.2019.06.004>
- Zhu, N., Liu, X., Liu, Z., Hu, K., Wang, Y., Tan, J., Huang, M., Zhu, Q., Ji, X., Jiang, Y., & Guo, Y. (2018). Deep learning for smart agriculture: Concepts, tools, applications, and opportunities. *International Journal of Agricultural and Biological Engineering*, 11(4), 32-44. <https://doi.org/10.25165/j.ijabe.20181104.4475>
- Zou, K., Yin, M., Huang, W., & Zeng, Y. (2019). Deep stacked bidirectional LSTM neural network for skeleton-based action recognition. In *International Conference on Image and Graphics* (pp. 676-688). Springer, Cham.
- Zwierzyński, P. (2019, June). Conversion of a serial line assembly into a cellular structure. In *2019 IEEE Technology & Engineering Management Conference (TEMSCON)* (pp. 1-5). IEEE. Atlanta, GA, USA. <https://doi.org/10.1109/TEMSCON.2019.8813614>
- Zwierzyński, P., & Ahmad, H. (2018). Seru production as an alternative to a traditional assembly line. *Engineering Management in Production and Services*, 10(3), 62-69. <https://doi.org/10.2478/emj-2018-0017>

EKLER

EK A. Etik Kurul İzin Belgeleri

EK B. Montaj Hattında montaj eylemi tanıma deneylerinde elde edilen karmaşıklık matrisleri

EK C. Seru Üretim Sisteminde montaj eylemi tanıma deneylerinde elde edilen karmaşıklık matrisleri

EK A



T.C.
SAKARYA ÜNİVERSİTESİ REKTÖRLÜĞÜ
Etik Kurulu



Sayı : E-61923333-050.99-217441
Konu : 32/03 Arş. Gör. Merve ŞİŞÇİ

02.02.2023

Sayın Merve ŞİŞÇİ

İlgi : 13.01.2023 tarihli ve E--000-0 sayılı yazınız.

Üniversitemiz Fen ve Mühendislik Bilimleri Etik Kurulunun 18.01.2023 tarihli ve 32 sayılı toplantısında alınan "03" nolu karar ile Arş. Gör. Merve ŞİŞÇİ'nin başvurusu **uygun** görülmüş ve karar örneği ekte sunulmuştur.

Bilgilerinizi rica ederim.

Prof. Dr. Şenol YILMAZ
Fen ve Mühendislik Bilimleri Etik Kurul
Başkanı

Ek: Karar Yazısı (1 Sayfa)

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Doğrulama Kodu :BSRKNRZ5E Pın Kodu :18392

Belge Takip Adresi : <https://turkiye.gov.tr/ebd?ek=5783&eD=BSRKNRZ5E&eS=217441>

Adres:Esentepe Kampüsü 54187 Serdivan SAKARYA / KEP Adresi:

sakaryauniversitesi@hs01.kep.tr

Telefon No:0264 295 50 00 Faks No:0264 295 50 31

e-Posta:ozelkalem@sakarya.edu.tr Elektronik Ağ:www.sakarya.edu.tr

Bilgi için: Hanife Babacan

Unvanı: Birim Evrak Sorumlusu



Şekil A.1. Etik Kurul İzin Belgesi.

KARAR

3. Arş. Gör. Merve ŞİŞCİ'nin " SERU Üretim Kontrolü İçin Gerçek Zamanlı Görüntü İşleme Sistem Tasarımı Model Önerisi " başlıklı çalışması görüşmeye açıldı.

Yapılan görüşmeler sonunda Arş. Gör. Merve ŞİŞCİ'nin " SERU Üretim Kontrolü İçin Gerçek Zamanlı Görüntü İşleme Sistem Tasarımı Model Önerisi " başlıklı çalışmasının Etik açıdan **uygun** olduğuna oy birliği ile karar verildi.

Şekil A.2. Etik Kurul Kararı.

EK B

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	39	0	0	1	1	0	0	0	0	0	0	0	0	0	0
	ME2	1	43	5	3	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	4	21	3	0	0	0	0	0	1	0	0	0	0	0
	ME4	0	4	1	25	2	0	0	0	0	0	0	3	0	0	0
	ME5	1	1	0	3	107	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	3	43	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	4	100	8	1	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	51	3	0	0	0	0	0	0
	ME9	0	0	1	0	0	0	0	0	23	2	0	1	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	38	5	0	2	2	0
	ME11	0	0	0	0	0	0	0	0	0	7	22	5	0	0	0
	ME12	0	0	0	0	3	0	0	0	1	4	2	64	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	83	7	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	3	29	5
	ME15	1	0	0	0	0	0	0	0	0	0	0	0	3	2	22

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	38	2	0	0	0	0	1	0	0	0	0	0	0	0	0
	ME2	2	44	4	1	2	0	0	0	0	0	0	0	0	0	0
	ME3	0	3	23	3	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	4	3	25	2	0	0	0	0	0	0	1	0	0	0
	ME5	0	3	0	1	108	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	44	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	1	107	5	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	1	51	2	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	25	2	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	39	4	1	1	2	0
	ME11	0	0	0	0	0	0	0	0	0	4	28	2	0	0	0
	ME12	0	0	0	0	4	0	0	0	0	4	0	66	0	0	0
	ME13	1	0	0	0	1	0	0	0	0	0	0	4	81	5	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	1	31	5
	ME15	1	0	0	0	0	0	0	0	0	1	0	0	1	2	23

(b)

Şekil B.1. V_{eller} veri seti üzerinde geliştirilen CNN Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	39	1	0	1	0	0	0	0	0	0	0	0	0	0	0
	ME2	1	40	7	5	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	1	24	4	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	4	30	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	1	1	110	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	1	45	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	1	110	1	1	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	25	2	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	39	4	2	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	4	29	1	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	2	1	71	0	0	0
	ME13	0	0	0	1	0	0	0	0	0	0	0	3	85	3	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	29	6
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	2	26

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	38	1	0	2	0	0	0	0	0	0	0	0	0	0	0
	ME2	0	45	4	4	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	1	23	5	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	2	32	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	1	111	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	112	1	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	45	0	2	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	3	31	0	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	2	0	72	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	86	4	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	0	32	5
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	28

(b)

Şekil B.2. V_{eller-vücut} veri seti üzerinde geliştirilen CNN Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	34	2	1	0	0	0	1	0	0	0	0	0	0	0	1
	ME2	1	33	6	5	7	0	1	0	0	0	0	0	0	0	0
	ME3	0	8	15	5	0	0	0	0	0	0	1	0	0	0	0
	ME4	0	2	2	25	4	0	0	0	0	0	0	2	0	0	0
	ME5	0	3	0	4	105	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	6	40	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	6	99	6	1	0	0	1	0	0	0
	ME8	0	0	0	0	0	0	1	50	3	0	0	0	0	0	0
	ME9	0	2	0	0	0	0	0	3	19	3	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	37	8	1	1	0	0
	ME11	0	0	0	0	0	0	0	0	0	3	27	4	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	7	1	66	0	0	0
	ME13	0	0	0	2	0	0	0	0	0	0	0	8	80	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	27	8
	ME15	1	0	0	0	0	0	0	0	0	0	0	0	2	1	24

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	36	2	1	0	2	0	0	0	0	0	0	0	0	0	0
	ME2	2	37	6	6	2	0	0	0	0	0	0	0	0	0	0
	ME3	0	3	20	5	1	0	0	0	0	0	0	0	0	0	0
	ME4	1	0	1	31	2	0	0	0	0	0	0	0	0	0	0
	ME5	0	2	0	2	108	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	5	40	1	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	1	2	106	4	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	51	3	0	0	0	0	0	0
	ME9	0	1	0	0	0	0	0	1	24	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	1	0	0	36	8	2	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	1	27	6	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	5	0	69	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	5	85	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	27	8
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	2	3	21

(b)

Şekil B.3. V_{eller} veri seti üzerinde geliştirilen LSTM Modellerine ait karmaşıklık matrisleri: (a) Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	36	3	0	1	1	0	0	0	0	0	0	0	0	0	0
	ME2	2	36	6	7	2	0	0	0	0	0	0	0	0	0	0
	ME3	0	1	20	6	2	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	4	29	2	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	1	1	109	1	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	44	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	4	107	2	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	51	3	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	1	1	21	4	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	34	4	5	3	0	0
	ME11	0	0	0	0	0	0	0	0	0	6	24	4	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	5	4	65	0	0	0
	ME13	1	0	0	0	1	1	0	1	0	0	1	5	77	5	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	17	18
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	2	1	23

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	32	2	0	1	3	0	0	0	0	0	1	0	0	0	2
	ME2	3	29	7	9	4	0	0	0	1	0	0	0	0	0	0
	ME3	0	1	24	4	0	0	0	0	0	0	0	0	0	0	0
	ME4	1	0	2	31	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	2	1	109	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	44	2	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	1	2	105	5	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	25	2	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	34	7	3	2	0	0
	ME11	0	0	0	0	0	0	0	0	0	4	27	3	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	4	4	66	0	0	0
	ME13	1	0	0	0	0	0	0	0	0	0	0	1	84	6	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	3	18	16
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	0	1	25

(b)

Şekil B.4. $V_{eller-vücut}$ veri seti üzerinde geliştirilen LSTM Modellerine ait karmaşıklık matrisleri: (a) Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	35	4	0	2	0	0	0	0	0	0	0	0	0	0	0
	ME2	1	44	5	1	2	0	0	0	0	0	0	0	0	0	0
	ME3	0	2	21	6	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	2	3	26	2	0	0	0	0	0	0	2	0	0	0
	ME5	0	2	1	0	105	0	0	0	0	0	0	4	0	0	0
	ME6	0	0	0	0	4	42	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	108	5	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	25	1	0	0	1	0	0
	ME10	0	0	0	0	0	0	0	0	0	35	3	6	3	0	0
	ME11	0	0	0	0	0	0	0	0	0	7	26	1	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	3	1	70	0	0	0
	ME13	0	0	0	1	0	0	0	0	0	0	0	6	82	3	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	29	6
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	0	2	24

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	37	0	1	1	1	0	1	0	0	0	0	0	0	0	0
	ME2	1	37	8	3	4	0	0	0	0	0	0	0	0	0	0
	ME3	0	2	22	5	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	4	30	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	1	1	0	110	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	44	0	0	0	0	0	0	0	0	0
	ME7	0	3	1	0	0	1	106	2	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	1	0	50	3	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	36	3	1	1	3	3
	ME11	0	0	0	0	0	0	0	0	0	4	29	1	0	0	0
	ME12	0	0	0	0	3	0	0	0	0	3	2	66	0	0	0
	ME13	0	0	0	0	1	0	0	0	0	0	0	5	85	1	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	31	4
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	1	0	25

(b)

Şekil B.5. V_{eller} veri seti üzerinde geliştirilen GRU Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	37	2	0	1	1	0	0	0	0	0	0	0	0	0	0
	ME2	3	36	9	3	2	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	24	5	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	3	30	2	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	1	111	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	113	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	44	0	3	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	8	25	1	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	0	4	70	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	87	3	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	4	27	6
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	1	0	27

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	38	2	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	1	44	7	1	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	28	1	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	3	31	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	2	0	0	110	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	113	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	43	0	3	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	5	29	0	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	0	3	71	0	0	0
	ME13	0	0	0	0	0	0	1	0	0	0	0	2	87	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	30	5
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	28

(b)

Şekil B.6. $V_{eller-vücut}$ veri seti üzerinde geliştirilen GRU Modellerine ait karmaşıklık matrisleri: (a)Veri artırma yaklaşımı uygulanmadığında. (b) Veri artırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	38	0	1	2	0	0	0	0	0	0	0	0	0	0	0
	ME2	3	31	7	10	2	0	0	0	0	0	0	0	0	0	0
	ME3	0	2	20	7	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	4	1	28	1	0	0	0	0	0	0	1	0	0	0
	ME5	1	1	0	1	109	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	3	43	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	1	105	5	2	0	0	0	0	0	0
	ME8	0	1	0	0	0	0	2	50	1	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	36	7	3	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	1	32	1	0	0	0
	ME12	0	0	0	0	3	0	0	0	0	4	2	65	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	1	0	4	85	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	1	27	9
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	2	0	24

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	37	0	1	1	1	0	1	0	0	0	0	0	0	0	0
	ME2	1	37	8	3	4	0	0	0	0	0	0	0	0	0	0
	ME3	0	2	22	5	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	4	30	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	1	1	0	110	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	44	0	0	0	0	0	0	0	0	0
	ME7	0	3	1	0	0	1	106	2	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	1	0	50	3	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	36	3	1	1	3	3
	ME11	0	0	0	0	0	0	0	0	0	4	29	1	0	0	0
	ME12	0	0	0	0	3	0	0	0	0	3	2	66	0	0	0
	ME13	0	0	0	0	1	0	0	0	0	0	0	5	85	1	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	31	4
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	1	0	25

(b)

Şekil B.7. V_{eller} veri seti üzerinde geliştirilen BiLSTM Modellerine ait karmaşıklık matrisleri: (a) Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	37	0	0	2	2	0	0	0	0	0	0	0	0	0	0
	ME2	1	39	5	7	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	2	24	3	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	3	2	28	2	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	3	109	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	1	112	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	52	2	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	41	2	3	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	2	32	0	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	3	1	70	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	83	7	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	22	13
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	28

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	37	0	0	4	0	0	0	0	0	0	0	0	0	0	0
	ME2	0	40	1	6	6	0	0	0	0	0	0	0	0	0	0
	ME3	0	1	23	5	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	1	2	29	3	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	1	111	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	112	1	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	41	1	4	0	1	0
	ME11	0	0	0	0	0	0	0	0	0	2	32	0	0	0	0
	ME12	0	0	0	0	2	0	0	0	0	2	1	69	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	84	6	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	27	8
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	28

(b)

Şekil B.8. V_{eller-vücut} veri seti üzerinde geliştirilen BiLSTM Modellerine ait karmaşıklık matrisleri: (a)Veri artırma yaklaşımı uygulanmadığında. (b) Veri artırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	37	0	0	1	1	0	2	0	0	0	0	0	0	0	0
	ME2	2	38	1	8	4	0	0	0	0	0	0	0	0	0	0
	ME3	0	3	21	5	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	3	2	29	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	2	0	2	108	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	44	0	0	0	0	0	0	0	0	0
	ME7	0	0	1	0	1	2	103	6	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	53	1	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	1	0	24	2	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	35	3	4	3	0	2
	ME11	0	0	0	0	0	0	0	0	0	1	29	4	0	0	0
	ME12	0	0	0	0	3	0	0	0	0	2	2	67	0	0	0
	ME13	0	0	0	1	0	0	0	0	0	4	0	4	79	4	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	31	4
	ME15	1	0	0	0	0	0	0	0	0	0	0	0	4	2	21

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	36	0	1	1	1	1	1	0	0	0	0	0	0	0	0
	ME2	2	43	2	3	2	0	1	0	0	0	0	0	0	0	0
	ME3	0	0	23	6	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	3	2	28	2	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	0	112	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	44	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	110	2	0	0	0	0	0	0	1
	ME8	0	0	0	0	0	0	1	52	1	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	39	2	3	3	0	0
	ME11	0	0	0	0	0	0	0	0	0	1	30	2	1	0	0
	ME12	0	0	0	0	4	0	0	0	0	0	1	67	2	0	0
	ME13	0	0	0	2	0	1	0	0	0	1	0	4	81	3	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	3	29	5
	ME15	1	0	0	0	0	0	0	0	0	0	0	0	2	1	24

(b)

Şekil B.9. V_{eller} veri seti üzerinde geliştirilen BiGRU Modellerine ait karmaşıklık matrisleri: (a) Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	37	1	1	2	0	0	0	0	0	0	0	0	0	0	0
	ME2	0	38	10	5	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	23	6	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	4	30	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	0	112	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	113	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	44	0	3	0	0	0
	ME11	0	0	0	0	0	0	0	0	1	1	32	0	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	3	1	70	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	87	3	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	28	7
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	1	27

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	38	1	0	2	0	0	0	0	0	0	0	0	0	0	0
	ME2	0	41	8	4	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	22	7	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	3	31	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	0	112	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	112	1	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	42	0	3	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	2	32	0	0	0	0
	ME12	0	0	0	0	0	2	0	0	0	0	3	69	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	88	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	0	34	3
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	2	26

(b)

Şekil B.10. $V_{eller-vücut}$ veri seti üzerinde geliştirilen BiGRU Modellerine ait karmaşıklık matrisleri: (a)Veri artırma yaklaşımı uygulanmadığında. (b) Veri artırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	35	2	0	0	2	0	0	0	0	0	2	0	0	0	0
	ME2	1	43	5	0	4	0	0	0	0	0	0	0	0	0	0
	ME3	0	6	16	7	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	1	2	29	3	0	0	0	0	0	0	0	0	0	0
	ME5	0	2	0	3	107	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	4	40	2	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	6	99	6	0	2	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	53	1	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	1	24	2	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	35	9	0	2	0	0
	ME11	0	0	0	0	0	0	0	0	0	3	27	4	0	0	0
	ME12	0	0	0	0	1	0	0	0	0	5	2	66	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	5	85	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	3	31	3
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	4	9	13

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	35	2	0	0	2	0	0	0	0	0	2	0	0	0	0
	ME2	1	46	4	1	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	3	19	5	2	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	2	32	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	2	0	0	109	0	0	0	0	0	1	0	0	0	0
	ME6	0	0	0	0	3	43	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	3	106	4	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	1	50	3	0	0	0	0	0	0
	ME9	0	0	0	1	0	0	1	0	22	3	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	36	6	3	0	1	1
	ME11	0	0	0	0	0	0	0	0	0	3	27	4	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	4	0	70	0	0	0
	ME13	0	0	0	1	0	0	0	0	0	0	0	2	86	3	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	3	27	7
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	1	27

(b)

Şekil B.11. V_{eller} veri seti üzerinde geliştirilen CNN-LSTM Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	36	3	0	1	1	0	0	0	0	0	0	0	0	0	0
	ME2	4	40	5	1	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	4	22	3	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	2	30	3	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	5	106	0	1	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	42	2	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	7	95	10	0	1	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	47	7	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	1	21	5	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	34	10	0	2	0	0
	ME11	0	0	0	0	0	0	0	0	0	5	23	6	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	5	0	68	1	0	0
	ME13	0	0	0	2	1	0	0	0	0	0	0	2	85	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	28	7
	ME15	7	0	0	0	0	0	0	0	0	0	0	0	2	3	16

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	7	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	1	45	4	3	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	1	24	4	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	3	31	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	1	1	110	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	45	1	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	4	109	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	25	2	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	40	3	0	3	0	0
	ME11	0	0	0	0	0	0	0	0	0	2	28	4	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	3	0	71	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	88	3	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	3	26	8
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	28

(b)

Şekil B.12. V_{eller-vücut} veri seti üzerinde geliştirilen CNN-LSTM Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	36	2	0	1	2	0	0	0	0	0	0	0	0	0	0
	ME2	1	44	6	1	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	2	22	4	1	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	2	32	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	2	0	1	109	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	3	43	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	2	104	7	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	53	1	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	23	4	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	36	7	1	1	1	0
	ME11	0	0	0	0	0	0	0	0	0	4	24	6	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	4	2	68	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	88	3	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	0	33	4
	ME15	1	0	0	0	0	0	0	0	0	0	0	0	0	0	27

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	35	3	0	2	1	0	0	0	0	0	0	0	0	0	0
	ME2	1	45	6	0	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	3	22	4	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	1	33	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	0	112	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	44	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	110	3	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	52	2	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	2	0	0	0	36	7	1	0	1	0
	ME11	0	0	0	0	0	0	0	0	0	2	27	5	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	4	0	70	0	0	0
	ME13	1	0	0	0	0	0	0	0	0	1	1	1	84	4	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	3	31	3
	ME15	1	0	0	0	0	0	0	0	0	0	0	0	0	1	26

(b)

Şekil B.13. V_{eller} veri seti üzerinde geliştirilen CNN-GRU Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	36	2	1	0	2	0	0	0	0	0	0	0	0	0	0
	ME2	1	42	4	6	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	1	22	6	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	2	33	0	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	1	1	110	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	113	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	42	4	1	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	1	29	4	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	1	1	72	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	91	1	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	29	6
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	26

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	37	1	1	1	1	0	0	0	0	0	0	0	0	0	0
	ME2	0	49	1	2	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	25	4	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	1	34	0	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	0	112	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	113	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	46	1	0	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	1	32	1	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	1	1	72	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	88	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	0	36	1
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	28

(b)

Şekil B.14. $V_{eller-vücut}$ veri seti üzerinde geliştirilen CNN-GRU Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	34	0	0	0	3	2	1	0	0	0	1	0	0	0	0
	ME2	1	47	0	4	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	3	19	7	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	2	2	31	0	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	3	109	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	3	43	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	3	103	5	0	2	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	51	3	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	37	5	2	2	0	0
	ME11	0	0	0	0	0	0	0	0	1	3	26	4	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	6	1	67	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	87	4	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	1	28	8
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	0	1	25

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	35	0	0	0	4	0	1	0	0	0	1	0	0	0	0
	ME2	1	47	2	0	3	0	0	0	0	0	0	0	0	0	0
	ME3	0	3	19	6	1	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	2	32	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	0	112	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	44	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	107	6	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	53	1	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	39	5	2	1	0	0
	ME11	0	0	0	0	0	0	0	0	0	3	28	3	0	0	0
	ME12	0	0	0	0	0	0	0	0	1	3	0	70	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	89	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	31	4
	ME15	1	0	0	0	0	0	0	0	0	0	0	0	0	1	26

(b)

Şekil B.15. V_{eller} veri seti üzerinde geliştirilen CNN-BiLSTM Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	35	0	0	4	2	0	0	0	0	0	0	0	0	0	0
	ME2	1	41	2	8	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	1	23	5	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	1	34	0	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	1	111	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	113	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	53	1	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	45	1	1	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	1	32	1	0	0	0
	ME12	0	0	0	0	0	0	0	0	1	1	1	71	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	89	1	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	0	35	2
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	0	1	25

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	38	0	0	3	0	0	0	0	0	0	0	0	0	0	0
	ME2	0	43	2	8	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	25	4	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	2	33	0	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	1	111	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	113	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	46	0	1	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	2	32	0	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	0	0	74	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	90	1	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	0	36	1
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	28

(b)

Şekil B.16. $V_{eller-vücut}$ veri seti üzerinde geliştirilen CNN-BiLSTM Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	35	0	0	2	2	1	0	0	0	0	0	0	0	0	1
	ME2	3	43	5	1	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	3	21	3	1	0	0	0	0	1	0	0	0	0	0
	ME4	0	0	1	33	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	1	111	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	3	43	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	4	103	6	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	52	2	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	35	6	3	2	0	0
	ME11	0	0	0	0	0	0	0	0	0	3	27	2	0	2	0
	ME12	0	0	0	0	2	0	0	0	1	1	0	69	0	1	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	86	5	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	0	34	3
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	2	26

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	37	0	0	1	1	0	0	0	0	0	2	0	0	0	0
	ME2	2	45	4	1	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	2	24	3	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	1	1	33	0	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	0	112	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	3	43	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	108	5	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	50	4	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	37	5	2	1	0	0
	ME11	0	0	0	0	0	0	0	0	0	2	27	5	0	0	0
	ME12	0	0	0	0	0	0	0	0	1	2	0	71	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	87	3	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	1	32	4
	ME15	1	0	0	0	0	0	0	0	0	0	0	0	0	0	27

(b)

Şekil B.17. V_{eller} veri seti üzerinde geliştirilen CNN-BiGRU Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	36	0	0	3	2	0	0	0	0	0	0	0	0	0	0
	ME2	0	48	0	5	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	22	7	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	1	33	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	0	112	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	1	112	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	45	0	2	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	1	30	3	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	0	1	73	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	89	1	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	35	0
	ME15	3	0	0	0	0	0	0	0	0	0	0	0	0	0	25

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	38	0	0	2	1	0	0	0	0	0	0	0	0	0	0
	ME2	0	51	0	2	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	25	4	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	0	35	0	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	1	111	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	113	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	47	0	0	0	0	0
	ME11	0	0	0	0	0	0	0	0	1	0	32	1	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	3	0	71	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	89	1	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	32	3
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	28

(b)

Şekil B.18. Veller-vücut veri seti üzerinde geliştirilen CNN-BiGRU Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	37	0	0	0	4	0	0	0	0	0	0	0	0	0	0
	ME2	3	46	3	0	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	1	22	4	2	0	0	0	0	0	0	0	0	0	0
	ME4	0	1	1	33	0	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	3	108	0	0	0	0	0	1	0	0	0	0
	ME6	0	0	0	0	2	44	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	4	104	5	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	51	3	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	33	9	3	0	1	0
	ME11	0	0	0	0	0	0	0	0	0	2	26	6	0	0	0
	ME12	0	0	0	0	0	0	0	0	3	2	0	69	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	88	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	31	4
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	2	0	26

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	37	0	0	1	3	0	0	0	0	0	0	0	0	0	0
	ME2	1	48	1	2	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	3	21	4	1	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	2	33	0	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	0	112	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	44	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	3	105	5	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	1	51	2	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0
	ME10	0	0	0	0	0	1	0	0	0	37	5	2	2	0	0
	ME11	0	0	0	0	0	0	0	0	0	1	29	2	1	1	0
	ME12	0	0	0	0	0	0	0	0	1	2	0	71	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	88	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	1	31	5
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	1	27

(b)

Şekil B.19. V_{eller} veri seti üzerinde geliştirilen CNN-BiGRU-CNN Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	35	0	0	4	1	0	0	0	0	0	0	0	0	0	1
	ME2	1	47	1	4	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	25	4	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	1	1	32	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	0	112	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	113	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	1	53	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	45	0	2	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	1	31	2	0	0	0
	ME12	0	0	0	0	0	0	0	0	1	1	1	71	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	89	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	1	31	5
	ME15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	28

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	39	0	0	2	0	0	0	0	0	0	0	0	0	0	0
	ME2	0	50	0	2	1	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	24	5	0	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	1	34	0	0	0	0	0	0	0	0	0	0	0
	ME5	0	0	0	1	111	0	0	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	0	46	0	0	0	0	0	0	0	0	0
	ME7	0	0	0	0	0	0	113	0	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	0	27	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	46	0	1	0	0	0
	ME11	0	0	0	0	0	0	0	0	1	0	33	0	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	0	2	72	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	2	88	2	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	1	36	0
	ME15	1	0	0	0	0	0	0	0	0	0	0	0	0	0	27

(b)

Şekil B.20. $V_{eller-vücut}$ veri seti üzerinde geliştirilen CNN-BiGRU-CNN Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

EK C

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	31	1	0	0	0	0	0	0	0	0	0	0	1	0	2
	ME2	3	54	3	6	2	0	1	1	0	0	0	0	0	1	0
	ME3	0	6	77	1	5	0	1	3	2	0	1	0	0	0	0
	ME4	0	0	6	44	2	0	5	0	2	0	0	0	0	1	0
	ME5	0	0	3	2	163	1	9	1	0	0	1	1	0	0	0
	ME6	0	0	2	0	3	49	2	0	0	0	2	0	0	0	0
	ME7	0	0	5	2	12	2	123	1	1	0	1	0	0	0	1
	ME8	0	0	0	0	0	0	1	105	1	0	0	3	1	0	0
	ME9	0	0	0	1	0	0	0	6	32	2	0	0	1	0	0
	ME10	0	0	1	0	0	0	0	0	1	44	1	1	0	0	0
	ME11	1	0	0	0	1	0	0	0	0	5	56	2	0	0	1
	ME12	0	1	0	0	0	0	0	1	0	0	4	129	0	2	0
	ME13	1	0	0	0	0	0	0	0	0	0	0	0	94	1	2
	ME14	0	1	0	0	0	0	0	0	0	0	0	0	6	33	2
	ME15	2	1	0	0	0	0	0	0	0	0	0	0	1	0	45

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	32	1	0	0	0	0	0	0	0	0	0	1	0	0	1
	ME2	1	59	2	2	4	0	0	0	0	0	0	1	0	2	0
	ME3	0	4	80	3	4	0	0	1	2	0	0	2	0	0	0
	ME4	0	0	4	49	3	0	2	0	1	0	1	0	0	0	0
	ME5	0	0	1	2	165	2	8	0	0	1	0	2	0	0	0
	ME6	0	0	1	0	2	51	2	0	0	0	2	0	0	0	0
	ME7	0	0	2	2	11	1	130	1	0	0	0	0	0	0	1
	ME8	0	0	0	0	0	0	3	98	4	0	0	4	2	0	0
	ME9	0	0	0	0	0	0	0	6	33	2	0	0	1	0	0
	ME10	0	0	1	0	0	0	0	0	3	43	1	0	0	0	0
	ME11	0	0	1	0	0	0	1	0	0	4	58	2	0	0	0
	ME12	0	2	0	0	0	0	0	2	0	0	2	128	2	1	0
	ME13	0	1	0	0	0	0	0	0	0	0	0	0	97	0	0
	ME14	0	1	0	0	0	0	0	0	0	0	0	0	5	33	3
	ME15	3	0	0	0	0	0	0	0	0	0	0	1	1	0	44

(b)

Şekil C.1. V_{eller} veri seti üzerinde geliştirilen CNN Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	1	0	0	0	0	0	0	0	0	0	0	0	0	0
	ME2	2	54	13	0	0	0	2	0	0	0	0	0	0	0	0
	ME3	0	3	91	0	1	0	0	0	0	0	1	0	0	0	0
	ME4	0	1	15	37	2	0	4	0	0	0	1	0	0	0	0
	ME5	0	1	3	1	163	1	0	5	0	0	1	4	0	0	0
	ME6	0	0	1	0	5	43	1	0	6	1	1	0	0	0	0
	ME7	0	1	12	2	15	3	99	4	0	0	5	5	0	0	0
	ME8	0	0	2	0	0	0	1	99	5	0	0	4	0	0	0
	ME9	0	0	0	0	0	1	0	8	32	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	5	38	5	0	0	0	0
	ME11	0	0	0	0	0	2	1	0	2	6	52	3	0	0	0
	ME12	0	1	0	0	0	0	0	1	0	0	1	132	1	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	97	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	7	32	0
	ME15	3	0	1	0	0	0	0	0	0	0	1	0	1	3	40

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	0	0	0	0	0	0	0	0	0	0	0	0	0	2
	ME2	0	59	10	0	0	0	2	0	0	0	0	0	0	0	0
	ME3	0	2	91	0	0	0	0	0	0	0	1	0	0	1	1
	ME4	0	0	12	44	2	0	1	0	0	1	0	0	0	0	0
	ME5	0	0	3	1	170	1	0	0	0	0	1	3	0	0	2
	ME6	0	0	0	0	3	50	1	0	0	1	3	0	0	0	0
	ME7	0	0	9	0	18	0	106	5	1	0	1	6	0	2	0
	ME8	0	0	4	0	0	0	2	98	5	0	0	2	0	0	0
	ME9	0	0	0	0	0	0	0	7	35	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	43	2	1	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	3	57	5	0	0	1
	ME12	0	0	0	0	0	0	0	0	0	2	1	132	0	0	2
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	9	32	1
	ME15	2	0	0	0	0	0	0	0	1	0	0	2	0	2	42

(b)

Şekil C.2. $V_{eller-vücut}$ veri seti üzerinde geliştirilen CNN Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	1	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	2	53	9	1	1	1	2	0	0	0	0	0	0	0	2
	ME3	0	4	86	1	1	0	0	1	0	0	0	1	2	0	0
	ME4	0	0	2	53	2	0	1	0	2	0	0	0	0	0	0
	ME5	0	0	2	2	167	5	3	2	0	0	0	0	0	0	0
	ME6	0	0	1	0	4	49	2	0	0	0	2	0	0	0	0
	ME7	0	3	2	0	14	3	119	3	0	0	1	0	0	0	3
	ME8	0	0	0	0	0	0	2	101	2	0	0	3	3	0	0
	ME9	0	0	0	0	0	0	0	8	31	1	0	2	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	43	3	0	0	0	0
	ME11	0	1	1	0	1	0	0	0	0	5	55	3	0	0	0
	ME12	0	1	0	0	0	0	0	1	0	0	2	129	2	0	2
	ME13	0	0	0	1	0	0	0	0	0	0	0	0	96	1	0
	ME14	0	0	0	0	0	0	0	0	0	1	0	0	7	33	1
	ME15	5	1	0	0	0	0	0	0	0	0	0	0	1	2	40

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	32	1	0	0	0	0	0	0	0	0	0	0	1	0	1
	ME2	2	57	6	1	1	0	3	0	0	0	0	0	1	0	0
	ME3	0	4	83	1	3	0	0	2	0	0	0	2	0	1	0
	ME4	0	0	0	51	3	0	2	0	3	0	0	1	0	0	0
	ME5	0	0	0	3	172	4	2	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	3	53	1	0	0	0	1	0	0	0	0
	ME7	0	1	4	1	12	2	120	5	0	0	0	0	1	0	2
	ME8	0	0	0	0	0	0	2	97	5	0	0	5	2	0	0
	ME9	0	0	0	0	0	0	0	8	29	2	0	2	1	0	0
	ME10	0	0	1	0	0	0	0	0	1	44	2	0	0	0	0
	ME11	0	1	0	0	0	0	0	0	0	4	55	6	0	0	0
	ME12	0	1	0	1	0	0	0	0	2	0	1	128	2	0	2
	ME13	0	0	0	1	0	0	0	0	0	0	0	1	96	0	0
	ME14	0	1	0	0	0	0	1	0	0	0	0	0	6	33	1
	ME15	3	1	0	0	0	0	0	0	0	0	0	1	1	1	42

(b)

Şekil C.3. V_{eller} veri seti üzerinde geliştirilen LSTM Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	31	0	0	0	0	0	0	0	0	0	0	1	2	0	1
	ME2	2	53	11	0	1	0	2	1	0	0	0	1	0	0	0
	ME3	0	6	80	6	0	0	2	0	0	0	1	1	0	0	0
	ME4	0	2	6	44	3	0	1	0	2	0	2	0	0	0	0
	ME5	0	0	4	1	165	7	1	3	0	0	0	0	0	0	0
	ME6	0	0	3	0	2	48	2	0	0	0	2	0	0	0	1
	ME7	4	6	13	3	20	2	89	4	0	0	2	0	0	0	0
	ME8	0	0	2	0	0	0	3	103	0	0	2	5	0	0	0
	ME9	0	0	1	0	0	1	0	9	28	0	3	1	0	0	0
	ME10	0	0	0	0	0	0	0	1	5	39	3	0	0	0	0
	ME11	0	0	0	0	0	2	1	2	0	4	53	4	0	0	0
	ME12	0	0	0	0	1	0	1	0	0	0	2	130	1	1	1
	ME13	1	0	0	0	0	0	0	0	0	0	0	0	96	1	0
	ME14	0	0	1	0	0	0	0	0	0	0	1	0	14	25	1
	ME15	4	0	1	0	0	0	2	0	0	0	0	3	1	2	36

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	31	0	0	0	0	0	0	0	0	0	0	0	4	0	0
	ME2	1	58	6	1	0	0	4	0	0	0	0	1	0	0	0
	ME3	0	3	83	5	0	0	2	3	0	0	0	0	0	0	0
	ME4	0	0	5	51	2	0	2	0	0	0	0	0	0	0	0
	ME5	0	0	2	2	168	4	1	2	0	0	1	1	0	0	0
	ME6	0	0	3	0	1	46	5	1	0	0	2	0	0	0	0
	ME7	0	7	9	2	7	1	105	5	1	0	2	2	0	3	4
	ME8	0	0	4	0	0	0	6	101	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	1	0	10	31	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	1	11	32	4	0	0	0	0
	ME11	0	0	0	0	1	2	0	0	1	2	55	4	0	1	0
	ME12	0	0	0	0	0	0	0	2	0	1	3	129	1	1	0
	ME13	0	0	0	1	0	0	0	0	0	0	0	2	94	1	0
	ME14	0	0	0	0	0	0	0	0	0	0	1	0	12	28	1
	ME15	0	0	1	0	0	0	4	4	0	0	0	1	0	1	32

(b)

Şekil C.4. $V_{eller-vücut}$ veri seti üzerinde geliştirilen LSTM Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	28	1	0	0	0	1	0	0	0	0	0	2	0	0	3
	ME2	1	63	1	0	2	0	3	1	0	0	0	0	0	0	0
	ME3	0	4	86	0	4	0	1	1	0	0	0	0	0	0	0
	ME4	0	0	1	51	3	0	3	0	2	0	0	0	0	0	0
	ME5	0	0	1	2	175	1	2	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	53	2	0	0	0	1	0	0	0	0
	ME7	0	5	3	0	9	2	124	2	0	0	0	1	0	2	0
	ME8	0	0	0	0	0	0	3	96	4	0	0	8	0	0	0
	ME9	0	0	0	0	0	0	0	8	29	3	0	2	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	44	2	0	0	0	0
	ME11	0	0	1	0	0	0	1	0	0	4	59	1	0	0	0
	ME12	2	0	0	2	0	0	0	1	1	3	1	126	1	0	0
	ME13	0	0	0	1	0	0	0	0	0	0	0	0	97	0	0
	ME14	0	1	0	0	0	0	1	0	1	0	0	0	4	35	0
	ME15	3	1	1	0	0	0	0	0	1	0	0	0	0	1	42

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	32	1	0	0	0	0	0	0	0	0	0	0	0	0	2
	ME2	1	64	1	0	0	0	1	1	0	0	0	3	0	0	0
	ME3	0	5	88	0	2	0	1	0	0	0	0	0	0	0	0
	ME4	0	0	0	56	2	0	1	0	1	0	0	0	0	0	0
	ME5	0	0	0	2	173	3	3	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	55	0	0	0	0	1	0	0	0	0
	ME7	0	2	0	2	9	1	132	1	0	0	0	1	0	0	0
	ME8	0	0	1	0	0	0	1	103	2	0	0	4	0	0	0
	ME9	0	0	0	0	0	0	0	5	32	4	0	1	0	0	0
	ME10	0	0	1	0	0	0	0	0	2	43	2	0	0	0	0
	ME11	0	0	0	0	0	0	1	0	0	3	60	2	0	0	0
	ME12	0	1	0	1	0	0	0	2	0	1	1	127	3	0	1
	ME13	0	0	0	0	0	0	1	0	0	0	0	0	96	1	0
	ME14	0	1	0	0	0	0	1	0	0	1	0	0	3	36	0
	ME15	2	0	0	0	0	0	0	0	0	0	0	1	2	0	44

(b)

Şekil C.5. V_{eller} veri seti üzerinde geliştirilen GRU Modellerine ait karmaşıklık matrisleri: (a) Veri artırma yaklaşımı uygulanmadığında. (b) Veri artırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	30	1	1	0	0	0	0	0	0	0	0	0	1	0	2
	ME2	1	61	9	0	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	5	88	0	1	0	0	2	0	0	0	0	0	0	0
	ME4	0	0	6	50	3	0	1	0	0	0	0	0	0	0	0
	ME5	1	0	2	2	163	3	4	3	1	0	0	2	0	0	0
	ME6	0	0	0	0	1	45	1	0	8	2	1	0	0	0	0
	ME7	2	2	6	3	11	2	111	6	0	0	2	0	0	0	3
	ME8	0	3	1	1	0	0	3	102	0	0	0	1	0	0	0
	ME9	0	0	0	0	0	2	0	7	33	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	44	2	0	0	0	0
	ME11	0	0	0	0	0	6	3	0	1	3	52	1	0	0	0
	ME12	2	0	2	0	0	0	0	1	0	0	1	129	2	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	5	36	1
	ME15	2	0	0	0	0	0	0	3	0	0	0	0	1	1	42

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	32	0	0	0	0	0	0	0	0	0	0	0	1	1	0
	ME2	1	62	5	0	0	0	1	2	0	0	0	0	0	0	0
	ME3	0	5	82	1	0	2	2	3	1	0	0	0	0	0	0
	ME4	0	0	4	54	1	0	0	0	0	0	1	0	0	0	0
	ME5	0	1	1	1	167	4	1	0	0	0	0	6	0	0	0
	ME6	0	0	0	0	1	51	0	0	0	0	6	0	0	0	0
	ME7	0	0	12	3	7	1	111	5	0	0	2	2	0	0	5
	ME8	0	3	2	0	0	0	3	102	0	0	0	1	0	0	0
	ME9	0	0	0	1	0	0	0	6	33	1	1	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	45	1	0	0	0	0
	ME11	0	0	0	0	0	1	2	0	1	2	59	1	0	0	0
	ME12	2	0	0	0	0	0	0	0	0	0	1	133	1	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	1	2	4	35	0
	ME15	2	0	0	0	0	0	0	1	1	0	0	0	0	1	44

(b)

Şekil C.6. V_{eller-vücut} veri seti üzerinde geliştirilen GRU Modellerine ait karmaşıklık matrisleri: (a)Veri artırma yaklaşımı uygulanmadığında. (b) Veri artırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	31	2	0	0	0	0	0	0	1	1	0	0	0	0	0
	ME2	3	52	5	0	5	0	5	0	0	0	0	0	0	1	0
	ME3	0	3	85	0	4	0	0	2	1	0	0	0	0	1	0
	ME4	0	1	4	48	3	0	3	0	1	0	0	0	0	0	0
	ME5	0	0	1	3	169	4	2	1	0	0	0	1	0	0	0
	ME6	0	0	0	0	3	52	0	1	0	0	2	0	0	0	0
	ME7	0	1	1	3	14	3	116	6	0	0	1	1	0	0	2
	ME8	0	0	1	0	0	1	2	101	2	0	0	3	1	0	0
	ME9	0	0	0	0	0	1	0	3	28	4	0	4	2	0	0
	ME10	0	0	1	0	0	0	1	0	1	43	2	0	0	0	0
	ME11	0	1	0	1	0	0	0	0	1	4	58	1	0	0	0
	ME12	0	1	0	2	0	0	0	1	1	2	3	121	3	0	3
	ME13	0	0	0	0	0	0	2	0	0	0	0	2	94	0	0
	ME14	0	1	0	0	0	0	1	1	0	1	0	0	4	31	3
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	5	0	42

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	0	0	0	0	0	0	0	1	0	0	0	0	0	1
	ME2	1	57	5	0	5	0	2	0	0	0	0	1	0	0	0
	ME3	0	3	88	0	1	1	0	1	2	0	0	0	0	0	0
	ME4	0	0	2	50	4	0	3	0	1	0	0	0	0	0	0
	ME5	0	0	0	2	175	2	2	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	3	54	0	0	0	0	1	0	0	0	0
	ME7	0	2	1	4	12	0	125	2	0	0	1	1	0	0	0
	ME8	0	0	1	0	0	0	4	100	2	0	0	4	0	0	0
	ME9	0	0	0	0	0	1	0	5	32	1	0	3	0	0	0
	ME10	0	0	0	1	0	0	0	0	1	44	2	0	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	5	60	1	0	0	0
	ME12	0	1	0	3	0	0	0	0	1	1	2	123	3	0	3
	ME13	0	2	0	0	0	0	0	0	0	0	0	0	95	1	0
	ME14	0	1	0	0	0	0	1	0	0	2	0	0	5	32	1
	ME15	4	0	0	0	0	0	0	0	0	0	0	0	0	0	40

(b)

Şekil C.7. V_{eller} veri seti üzerinde geliştirilen BiLSTM Modellerine ait karmaşıklık matrisleri: (a) Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	34	0	0	0	0	0	0	0	0	0	0	0	1	0	0
	ME2	1	60	8	0	0	0	1	0	0	1	0	0	0	0	0
	ME3	0	2	90	0	0	1	0	0	0	0	1	0	0	0	2
	ME4	0	0	9	43	3	0	4	0	0	0	1	0	0	0	0
	ME5	0	3	4	1	164	2	3	1	0	0	0	0	0	0	3
	ME6	0	0	1	1	2	47	0	0	2	3	1	1	0	0	0
	ME7	3	7	7	2	12	0	103	2	1	0	2	2	0	1	6
	ME8	0	1	1	0	0	0	6	100	2	0	0	1	0	0	0
	ME9	0	0	0	0	0	0	0	7	35	0	0	0	0	0	0
	ME10	0	0	1	0	0	0	0	1	5	38	3	0	0	0	0
	ME11	0	0	0	0	1	4	1	0	0	2	55	3	0	0	0
	ME12	1	0	0	1	0	0	0	0	2	4	0	123	2	0	4
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	9	32	1
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	2	5	40

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	0	0	0	0	0	0	0	0	0	0	2	0	0	0
	ME2	1	58	10	0	0	0	2	0	0	0	0	0	0	0	0
	ME3	0	4	89	2	0	0	0	0	0	0	0	0	0	0	1
	ME4	0	0	7	44	1	0	4	0	1	0	2	0	0	0	1
	ME5	0	0	2	1	166	2	1	1	0	0	0	4	0	0	4
	ME6	0	0	1	0	1	48	1	1	0	3	2	1	0	0	0
	ME7	2	3	13	2	11	0	99	4	0	2	0	4	0	3	5
	ME8	0	5	4	0	0	0	2	99	0	0	0	1	0	0	0
	ME9	0	0	0	0	0	0	0	6	36	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	1	2	37	8	0	0	0	0
	ME11	0	0	0	0	0	3	1	0	1	1	58	2	0	0	0
	ME12	0	0	0	1	0	0	0	1	2	2	0	127	1	0	3
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	2	7	32	1
	ME15	2	0	0	0	0	0	0	1	0	0	0	0	1	1	44

(b)

Şekil C.8. V_{eller-vücut} veri seti üzerinde geliştirilen BiLSTM Modellerine ait karmaşıklık matrisleri: (a)Veri artırma yaklaşımı uygulanmadığında. (b) Veri artırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	34	1	0	0	0	0	0	0	0	0	0	0	0	0	0
	ME2	1	59	0	0	6	0	3	0	0	0	0	1	0	0	1
	ME3	0	3	84	4	2	1	0	0	0	0	0	0	1	0	1
	ME4	0	0	0	49	4	0	5	0	2	0	0	0	0	0	0
	ME5	0	0	1	1	177	1	1	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	53	0	0	0	0	3	0	0	0	0
	ME7	0	0	2	0	10	0	130	2	0	0	1	1	0	2	0
	ME8	0	0	0	1	0	0	3	101	2	0	0	3	1	0	0
	ME9	0	0	0	1	0	0	0	5	34	1	0	0	1	0	0
	ME10	0	0	0	0	0	0	0	0	1	46	1	0	0	0	0
	ME11	0	0	0	1	1	0	0	0	0	3	60	1	0	0	0
	ME12	0	1	0	1	1	0	0	2	0	1	2	127	1	1	0
	ME13	0	0	0	0	1	0	0	0	0	0	0	0	94	2	1
	ME14	0	1	0	0	0	0	0	0	0	0	0	0	4	36	1
	ME15	2	0	0	0	0	0	0	0	1	0	0	0	3	2	41

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	0	0	0	0	0	0	0	0	0	0	1	0	0	1
	ME2	3	57	5	0	3	0	2	1	0	0	0	0	0	0	0
	ME3	0	3	87	1	3	0	0	1	0	1	0	0	0	0	0
	ME4	0	0	0	53	2	0	3	0	1	0	0	1	0	0	0
	ME5	0	0	0	1	178	1	0	0	0	0	1	0	0	0	0
	ME6	0	0	0	0	2	54	1	0	0	0	1	0	0	0	0
	ME7	0	2	4	0	8	0	129	4	0	0	1	0	0	0	0
	ME8	0	0	0	0	0	0	2	98	3	1	0	6	1	0	0
	ME9	0	0	0	1	0	0	0	3	35	1	0	2	0	0	0
	ME10	0	0	0	1	0	0	0	0	1	45	1	0	0	0	0
	ME11	0	0	0	1	0	0	0	0	0	3	60	2	0	0	0
	ME12	0	0	0	2	1	0	0	2	1	0	1	128	2	0	0
	ME13	0	1	0	0	0	0	0	0	0	0	0	0	97	0	0
	ME14	0	1	0	0	1	0	0	0	0	0	0	1	2	37	0
	ME15	3	0	0	1	0	0	0	0	0	0	0	2	2	1	40

(b)

Şekil C.9. V_{eller} veri seti üzerinde geliştirilen BiGRU Modellerine ait karmaşıklık matrisleri: (a) Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	35	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	ME2	2	63	3	0	0	0	3	0	0	0	0	0	0	0	0
	ME3	0	4	84	0	3	1	0	4	0	0	0	0	0	0	0
	ME4	0	0	3	51	2	0	1	0	1	0	2	0	0	0	0
	ME5	0	0	1	1	167	2	5	1	1	0	0	2	0	0	1
	ME6	0	0	1	0	2	53	0	0	1	0	1	0	0	0	0
	ME7	0	5	6	5	6	1	119	2	0	0	1	0	0	2	1
	ME8	0	1	2	0	0	0	2	105	0	0	0	1	0	0	0
	ME9	0	0	0	0	0	0	0	7	35	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	4	42	1	1	0	0	0
	ME11	0	1	0	0	0	2	3	0	0	2	56	2	0	0	0
	ME12	0	0	0	0	0	0	0	1	0	0	1	132	2	0	1
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	4	37	1
	ME15	1	0	0	0	0	0	1	2	0	0	0	1	3	3	38

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	35	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	ME2	1	63	5	0	2	0	0	0	0	0	0	0	0	0	0
	ME3	0	4	88	0	3	0	0	1	0	0	0	0	0	0	0
	ME4	0	0	4	50	2	0	2	0	2	0	0	0	0	0	0
	ME5	0	0	1	0	168	4	4	2	0	0	0	2	0	0	0
	ME6	0	0	0	0	1	48	1	0	5	0	3	0	0	0	0
	ME7	1	3	6	0	7	0	123	4	0	0	1	3	0	0	0
	ME8	0	3	4	0	0	0	1	101	1	0	0	1	0	0	0
	ME9	0	0	0	0	0	1	0	4	36	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	45	1	0	0	0	0
	ME11	0	0	0	0	0	4	0	0	0	0	61	1	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	0	0	136	1	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	1	0	5	35	1
	ME15	2	0	0	0	0	0	0	1	0	0	0	0	4	0	42

(b)

Şekil C.10. V_{eller-vücut} veri seti üzerinde geliştirilen BiGRU Modellerine ait karmaşıklık matrisleri: (a)Veri artırma yaklaşımı uygulanmadığında. (b) Veri artırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	1	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	2	53	9	1	1	1	2	0	0	0	0	0	0	0	2
	ME3	0	4	86	1	1	0	0	1	0	0	0	1	2	0	0
	ME4	0	0	2	53	2	0	1	0	2	0	0	0	0	0	0
	ME5	0	0	2	2	167	5	3	2	0	0	0	0	0	0	0
	ME6	0	0	1	0	4	49	2	0	0	0	2	0	0	0	0
	ME7	0	3	2	0	14	3	119	3	0	0	1	0	0	0	3
	ME8	0	0	0	0	0	0	2	101	2	0	0	3	3	0	0
	ME9	0	0	0	0	0	0	0	8	31	1	0	2	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	43	3	0	0	0	0
	ME11	0	1	1	0	1	0	0	0	0	5	55	3	0	0	0
	ME12	0	1	0	0	0	0	0	1	0	0	2	129	2	0	2
	ME13	0	0	0	1	0	0	0	0	0	0	0	0	96	1	0
	ME14	0	0	0	0	0	0	0	0	0	1	0	0	7	33	1
	ME15	5	1	0	0	0	0	0	0	0	0	0	0	1	2	40

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	1	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	1	65	3	0	1	0	0	1	0	0	0	0	0	0	0
	ME3	0	3	89	0	0	1	0	3	0	0	0	0	0	0	0
	ME4	0	0	2	54	3	0	1	0	0	0	0	0	0	0	0
	ME5	0	0	0	1	174	3	2	0	0	0	0	1	0	0	0
	ME6	0	0	1	0	4	52	0	0	0	0	1	0	0	0	0
	ME7	0	2	3	0	5	2	134	1	0	0	1	0	0	0	0
	ME8	0	0	0	0	0	0	3	101	5	0	0	1	1	0	0
	ME9	0	0	0	0	0	0	0	7	32	3	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	42	3	0	0	1	0
	ME11	0	0	0	0	0	0	1	0	0	4	58	3	0	0	0
	ME12	0	1	0	0	0	0	0	0	0	0	2	130	2	0	2
	ME13	0	0	0	0	0	0	2	0	0	0	0	0	96	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	4	36	2
	ME15	3	0	0	0	0	0	0	0	0	0	0	0	0	0	46

(b)

Şekil C.11. V_{eller} veri seti üzerinde geliştirilen CNN-LSTM Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	2	0	0	0	0	0	0	0	0	0	0	0	0	0
	ME2	3	59	8	0	0	0	0	0	0	0	0	0	0	0	1
	ME3	0	1	82	2	0	0	3	1	0	1	2	0	0	0	4
	ME4	0	0	7	40	6	2	3	0	1	0	0	1	0	0	0
	ME5	0	2	0	1	165	9	0	2	0	0	0	1	0	1	0
	ME6	0	0	2	0	8	39	2	2	1	0	2	0	0	0	2
	ME7	0	2	0	5	13	1	108	5	1	0	5	6	0	1	1
	ME8	0	0	1	0	0	0	3	104	3	0	0	0	0	0	0
	ME9	0	0	1	0	0	5	2	11	20	2	1	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	42	3	1	0	0	0
	ME11	0	0	0	0	0	1	0	0	0	6	55	4	0	0	0
	ME12	0	1	0	0	0	0	0	1	0	1	3	129	2	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	97	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	5	35	2
	ME15	8	0	0	0	0	0	0	0	0	1	0	1	0	4	35

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	31	3	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	0	66	4	0	0	0	1	0	0	0	0	0	0	0	0
	ME3	0	1	81	5	2	1	3	1	0	0	1	0	0	0	1
	ME4	0	0	4	51	3	0	2	0	0	0	0	0	0	0	0
	ME5	0	1	0	0	175	4	0	0	0	0	0	0	0	0	1
	ME6	0	0	0	0	3	48	2	0	2	2	0	0	0	0	1
	ME7	0	2	1	0	11	0	121	1	0	4	4	1	0	0	3
	ME8	0	0	0	0	0	0	2	109	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	4	0	7	30	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	3	41	4	0	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	3	62	1	0	0	0
	ME12	0	1	0	0	0	0	0	0	0	0	3	133	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	4	36	2
	ME15	5	0	0	0	0	0	0	0	0	0	0	0	0	1	43

(b)

Şekil C.12. $V_{eller-vücut}$ veri seti üzerinde geliştirilen CNN-LSTM Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	31	1	0	0	0	0	0	1	0	0	0	0	0	0	2
	ME2	2	62	6	0	0	0	0	0	0	0	1	0	0	0	0
	ME3	0	5	83	3	1	0	4	0	0	0	0	0	0	0	0
	ME4	0	1	3	46	5	0	2	0	0	0	3	0	0	0	0
	ME5	0	1	0	0	174	2	2	2	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	54	1	0	0	0	0	0	0	0	1
	ME7	0	1	3	1	5	3	130	3	0	0	1	0	0	0	1
	ME8	0	0	0	0	0	0	5	101	4	0	0	1	0	0	0
	ME9	0	0	0	0	0	0	0	8	31	2	0	0	0	0	0
	ME10	0	0	2	0	0	0	0	0	2	42	0	2	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	4	59	3	0	0	0
	ME12	0	1	0	0	0	0	0	0	0	0	2	134	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	97	0	0
	ME14	0	1	0	0	0	0	0	0	0	0	0	0	6	33	2
	ME15	4	0	0	0	0	0	0	0	0	0	0	0	0	1	44

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	34	1	0	0	0	0	0	0	0	0	0	0	0	0	0
	ME2	1	69	1	0	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	5	87	1	0	0	2	1	0	0	0	0	0	0	0
	ME4	0	0	3	50	4	0	2	0	1	0	0	0	0	0	0
	ME5	0	1	0	1	166	8	3	1	0	0	0	1	0	0	0
	ME6	0	0	1	0	2	53	1	0	0	0	1	0	0	0	0
	ME7	0	2	0	0	4	1	138	3	0	0	0	0	0	0	0
	ME8	0	0	0	0	0	0	2	102	6	0	0	1	0	0	0
	ME9	0	0	0	0	0	0	0	7	33	1	0	0	1	0	0
	ME10	0	0	2	0	0	0	0	0	4	39	3	0	0	0	0
	ME11	0	0	0	0	0	0	0	0	1	4	59	2	0	0	0
	ME12	0	0	0	0	0	0	1	0	1	0	2	131	2	0	0
	ME13	0	0	0	1	0	0	0	0	0	0	0	0	97	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	3	38	1
	ME15	3	0	0	0	0	0	0	0	0	0	0	0	0	1	45

(b)

Şekil C.13. V_{eller} veri seti üzerinde geliştirilen CNN-GRU Modellerine ait karmaşıklık matrisleri: (a) Veri artırma yaklaşımı uygulanmadığında. (b) Veri artırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	34	1	0	0	0	0	0	0	0	0	0	0	0	0	0
	ME2	2	64	4	0	0	0	0	1	0	0	0	0	0	0	0
	ME3	0	2	86	1	1	0	0	1	0	0	2	0	0	2	1
	ME4	0	0	5	48	2	0	5	0	0	0	0	0	0	0	0
	ME5	0	0	0	1	175	2	0	1	0	0	0	0	0	1	1
	ME6	0	0	0	0	5	43	4	0	1	0	4	0	1	0	0
	ME7	0	1	2	0	11	2	122	2	0	0	5	1	0	0	2
	ME8	0	0	1	0	0	0	2	104	1	0	1	2	0	0	0
	ME9	0	0	0	0	0	5	0	5	31	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	1	0	2	38	6	1	0	0	0
	ME11	0	0	0	0	1	0	0	0	0	3	62	0	0	0	0
	ME12	0	0	1	0	0	0	1	0	0	0	4	130	1	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	97	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	8	33	1
	ME15	4	0	0	0	0	0	0	0	0	1	0	0	0	2	42

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	34	0	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	0	71	0	0	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	91	0	4	0	0	1	0	0	0	0	0	0	0
	ME4	0	0	2	54	2	0	0	0	0	0	2	0	0	0	0
	ME5	0	0	0	0	174	3	0	3	0	0	0	0	0	1	0
	ME6	0	0	2	0	0	51	2	1	0	2	0	0	0	0	0
	ME7	0	0	1	1	5	0	133	1	0	0	4	2	0	0	1
	ME8	0	0	0	0	1	0	0	110	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	4	0	7	30	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	41	3	2	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	0	63	2	0	1	0
	ME12	0	0	0	0	0	0	1	1	0	0	1	133	1	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	40	0
	ME15	4	0	0	0	0	0	0	0	0	0	0	0	0	1	44

(b)

Şekil C.14. $V_{\text{eller-vücut}}$ veri seti üzerinde geliştirilen CNN-GRU Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	1	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	2	62	5	1	0	0	1	0	0	0	0	0	0	0	0
	ME3	0	4	81	1	0	5	4	0	1	0	0	0	0	0	0
	ME4	0	0	3	47	2	0	5	0	1	2	0	0	0	0	0
	ME5	0	0	0	3	166	4	5	3	0	0	0	0	0	0	0
	ME6	0	0	0	0	4	53	0	0	0	0	0	0	0	0	1
	ME7	0	6	2	0	2	3	128	5	0	0	1	0	0	0	1
	ME8	0	0	0	0	0	0	1	103	5	0	0	1	1	0	0
	ME9	0	0	0	0	0	0	0	7	34	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	3	43	1	1	0	0	0
	ME11	0	0	0	0	0	1	1	0	0	2	60	2	0	0	0
	ME12	0	0	0	0	0	0	1	0	0	0	2	133	1	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	1	97	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	3	38	1
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	0	0	47

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	32	1	0	0	0	0	0	0	0	0	0	0	0	0	2
	ME2	1	64	5	0	0	0	1	0	0	0	0	0	0	0	0
	ME3	0	4	88	0	0	0	3	1	0	0	0	0	0	0	0
	ME4	0	1	2	50	2	1	3	0	1	0	0	0	0	0	0
	ME5	0	0	1	2	171	4	3	0	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	54	1	0	0	1	0	0	0	0	0
	ME7	0	1	0	0	6	3	133	3	1	0	1	0	0	0	0
	ME8	0	0	1	0	0	0	2	103	3	0	0	1	1	0	0
	ME9	0	0	0	1	0	0	0	7	33	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	46	0	0	0	0	0
	ME11	0	0	0	0	0	2	1	0	0	2	58	3	0	0	0
	ME12	0	1	0	0	0	0	0	0	0	0	2	131	3	0	0
	ME13	0	0	0	0	0	0	2	0	0	0	0	0	96	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	4	37	1
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	0	1	46

(b)

Şekil C.15. V_{eller} veri seti üzerinde geliştirilen CNN-BiLSTM Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	32	1	0	0	0	0	0	0	0	0	0	0	0	0	2
	ME2	1	65	4	0	0	0	0	0	0	0	0	0	0	1	0
	ME3	0	0	87	0	0	2	2	0	0	0	3	0	0	2	0
	ME4	0	0	5	53	1	0	0	0	1	0	0	0	0	0	0
	ME5	0	0	1	0	172	4	0	1	0	0	0	0	0	2	1
	ME6	0	0	1	0	5	48	0	0	1	2	1	0	0	0	0
	ME7	0	3	3	4	6	0	126	1	0	1	2	0	0	2	0
	ME8	0	0	1	0	1	0	1	108	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	3	0	5	33	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	4	38	5	0	0	1	0
	ME11	0	0	0	0	0	0	0	0	0	1	65	0	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	0	2	133	2	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	2	0	0	0	0	0	0	0	0	0	0	3	37	0
	ME15	3	0	0	0	0	0	0	0	0	0	0	0	0	0	46

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	34	1	0	0	0	0	0	0	0	0	0	0	0	0	0
	ME2	0	69	2	0	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	90	0	0	0	3	0	0	0	0	0	0	2	0
	ME4	0	0	8	50	1	0	1	0	0	0	0	0	0	0	0
	ME5	0	2	0	0	170	6	0	0	0	0	0	0	0	3	0
	ME6	0	0	0	0	1	52	0	0	0	2	3	0	0	0	0
	ME7	0	0	3	0	7	0	125	1	0	3	3	3	0	1	2
	ME8	0	0	0	0	0	0	1	109	0	0	0	1	0	0	0
	ME9	0	0	0	0	0	3	0	3	35	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	39	6	1	0	0	0
	ME11	0	0	0	0	0	1	0	0	1	0	63	0	0	0	1
	ME12	0	0	0	0	0	0	0	0	0	0	2	134	1	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	40	0
	ME15	3	0	0	0	0	0	0	0	0	0	0	0	0	2	44

(b)

Şekil C.16. $V_{eller-vücut}$ veri seti üzerinde geliştirilen CNN-BiLSTM Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	1	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	2	65	4	0	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	5	82	2	4	1	2	0	0	0	0	0	0	0	0
	ME4	0	1	1	52	3	0	1	0	2	0	0	0	0	0	0
	ME5	0	1	0	2	171	3	3	1	0	0	0	0	0	0	0
	ME6	0	1	0	0	4	52	0	0	0	0	0	0	0	1	0
	ME7	1	5	2	0	4	2	126	3	0	0	1	0	0	0	4
	ME8	0	0	0	0	0	0	4	100	3	0	0	2	2	0	0
	ME9	0	0	0	0	0	1	0	8	33	0	0	0	0	0	0
	ME10	0	0	1	0	0	0	0	0	2	44	0	1	0	0	0
	ME11	0	0	0	0	0	1	0	0	1	2	61	1	0	0	0
	ME12	0	1	0	1	0	0	0	1	0	0	1	131	2	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	6	35	1
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	0	0	47

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	1	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	2	68	1	0	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	4	89	0	0	2	0	1	0	0	0	0	0	0	0
	ME4	0	1	2	53	2	0	0	0	2	0	0	0	0	0	0
	ME5	0	2	0	1	168	4	4	2	0	0	0	0	0	0	0
	ME6	0	0	0	0	2	54	0	0	1	1	0	0	0	0	0
	ME7	0	1	2	0	5	2	135	2	0	0	1	0	0	0	0
	ME8	0	0	0	0	0	0	2	101	5	0	0	2	1	0	0
	ME9	0	0	0	0	0	1	0	7	32	2	0	0	0	0	0
	ME10	0	0	0	0	1	0	0	0	1	45	1	0	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	5	58	3	0	0	0
	ME12	0	2	0	0	0	0	0	0	0	1	2	130	2	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	3	38	1
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	0	1	46

(b)

Şekil C.17. V_{eller} veri seti üzerinde geliştirilen CNN-BiGRU Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	32	2	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	1	66	4	0	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	3	90	1	2	0	0	0	0	0	0	0	0	0	0
	ME4	0	0	3	53	2	0	0	0	1	0	1	0	0	0	0
	ME5	0	3	0	0	174	1	0	1	0	0	0	0	0	2	0
	ME6	0	0	0	0	2	51	1	0	0	2	0	2	0	0	0
	ME7	0	2	1	0	7	0	129	1	0	0	4	1	0	0	3
	ME8	0	0	2	0	0	0	1	108	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	4	0	6	31	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	4	38	5	1	0	0	0
	ME11	0	0	0	0	0	1	0	0	0	2	63	0	0	0	0
	ME12	0	0	0	0	0	0	0	1	0	0	4	131	1	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	5	37	0
	ME15	3	0	0	0	0	0	0	0	0	0	0	0	0	0	46

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	34	0	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	0	70	1	0	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	91	0	2	1	2	0	0	0	0	0	0	0	0
	ME4	0	2	2	54	0	0	2	0	0	0	0	0	0	0	0
	ME5	0	1	0	0	176	2	0	2	0	0	0	0	0	0	0
	ME6	0	0	0	0	4	51	0	0	0	1	1	0	1	0	0
	ME7	0	0	1	1	4	1	133	1	0	0	3	2	0	0	2
	ME8	0	0	0	0	2	0	0	108	1	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	6	35	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	42	3	1	0	0	0
	ME11	0	0	0	0	0	1	0	0	0	2	63	0	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	0	1	136	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	40	0
	ME15	3	0	0	0	0	0	0	0	0	0	0	0	0	2	44

(b)

Şekil C.18. V_{eller-vücut} veri seti üzerinde geliştirilen CNN-BiGRU Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	34	0	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	1	64	6	0	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	6	83	1	1	1	2	0	1	0	1	0	0	0	0
	ME4	0	1	3	52	1	0	1	0	1	0	1	0	0	0	0
	ME5	0	0	0	1	167	5	5	2	0	0	0	1	0	0	0
	ME6	0	1	0	0	2	53	0	0	0	1	1	0	0	0	0
	ME7	0	4	0	0	3	2	130	3	0	0	3	0	0	0	3
	ME8	0	0	0	0	0	0	3	104	3	0	0	1	0	0	0
	ME9	0	0	0	0	0	0	0	6	35	1	0	0	0	0	0
	ME10	0	0	2	0	0	0	0	0	2	43	0	1	0	0	0
	ME11	0	0	0	0	0	0	0	1	0	4	59	2	0	0	0
	ME12	0	2	1	1	0	0	0	0	0	2	1	129	1	0	0
	ME13	0	0	0	0	0	0	2	0	0	0	0	0	96	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	3	38	1
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	0	1	46

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	33	1	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	1	66	3	0	0	0	1	0	0	0	0	0	0	0	0
	ME3	0	3	86	2	1	3	1	0	0	0	0	0	0	0	0
	ME4	0	2	4	49	3	0	2	0	0	0	0	0	0	0	0
	ME5	0	0	0	1	171	4	3	2	0	0	0	0	0	0	0
	ME6	0	0	1	0	2	55	0	0	0	0	0	0	0	0	0
	ME7	0	1	3	0	3	2	136	2	0	0	1	0	0	0	0
	ME8	0	0	0	0	0	0	3	103	4	0	0	1	0	0	0
	ME9	0	0	0	1	0	0	0	6	34	1	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	0	46	2	0	0	0	0
	ME11	0	0	0	0	0	0	1	0	0	3	59	3	0	0	0
	ME12	0	1	0	1	0	0	0	0	0	0	1	133	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	1	0	0	0	0	0	0	0	0	0	0	4	37	0
	ME15	2	0	0	0	0	0	0	0	0	0	0	0	0	1	46

(b)

Şekil C.19. V_{eller} veri seti üzerinde geliştirilen CNN-BiGRU-CNN Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	35	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	ME2	2	65	4	0	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	2	88	2	0	1	1	0	0	0	1	0	0	1	0
	ME4	0	0	6	51	1	0	1	0	0	1	0	0	0	0	0
	ME5	0	0	0	0	176	2	0	1	0	0	1	0	0	0	1
	ME6	0	0	0	0	1	50	0	0	2	1	4	0	0	0	0
	ME7	0	1	2	2	15	0	126	1	0	0	1	0	0	0	0
	ME8	0	0	0	0	0	0	1	109	0	1	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	7	33	2	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	2	44	2	0	0	0	0
	ME11	0	0	1	0	0	1	0	0	0	1	62	1	0	0	0
	ME12	0	0	1	0	0	0	0	0	0	0	2	132	2	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	4	37	1
	ME15	4	0	0	0	0	0	0	0	0	0	0	0	0	1	44

(a)

		Tahmin Edilen Eylem														
		ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15
Gerçekleşen Eylem	ME1	34	0	0	0	0	0	0	0	0	0	0	0	0	0	1
	ME2	0	71	0	0	0	0	0	0	0	0	0	0	0	0	0
	ME3	0	0	93	0	1	0	1	1	0	0	0	0	0	0	0
	ME4	0	2	1	56	1	0	0	0	0	0	0	0	0	0	0
	ME5	0	1	0	0	177	2	0	1	0	0	0	0	0	0	0
	ME6	0	0	2	0	2	51	2	0	0	1	0	0	0	0	0
	ME7	0	0	3	1	4	0	137	1	0	0	2	0	0	0	0
	ME8	0	0	0	0	0	0	2	109	0	0	0	0	0	0	0
	ME9	0	0	0	0	0	0	0	8	34	0	0	0	0	0	0
	ME10	0	0	0	0	0	0	0	0	1	44	3	0	0	0	0
	ME11	0	0	0	0	0	0	0	0	0	1	65	0	0	0	0
	ME12	0	0	0	0	0	0	0	0	0	0	0	137	0	0	0
	ME13	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0
	ME14	0	0	0	0	0	0	0	0	0	0	0	0	2	40	0
	ME15	3	0	0	0	0	0	0	0	0	0	0	0	0	0	46

(b)

Şekil C.20. V_{eller-vücut} veri seti üzerinde geliştirilen CNN-BiGRU-CNN Modellerine ait karmaşıklık matrisleri: (a)Veri arttırma yaklaşımı uygulanmadığında. (b) Veri arttırma yaklaşımı uygulandığında.

ÖZGEÇMİŞ

Ad-Soyad :Merve ŞİŞÇİ

ÖĞRENİM DURUMU:

- **Lisans** : 2013, Sakarya Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği
- **Yüksek Lisans** : 2017, Kütahya Dumlupınar Üniversitesi, Endüstri Mühendisliği Anabilim Dalı

MESLEKİ DENEYİM:

- 2014-2017 yılları arasında Dumlupınar Üniversitesi Endüstri Mühendisliği Bölümü'nde araştırma görevlisi olarak görev yapmıştır.
- 2018 yılından itibaren Sakarya Üniversitesi Endüstri Mühendisliği Bölümü'nde 35. Madde görevlendirme ile araştırma görevlisi olarak görev yapmaktadır.

TEZDEN TÜRETİLEN ESERLER:

- Torkul, O., Selvi, İ. H., ve Şişçi, M. (2022). Smart Seru Production System For Industry 4.0: A Conceptual Model Based On Deep Learning For Real-Time Monitoring And Controlling. *International Journal of Computer Integrated Manufacturing*, 1-23, doi.org/10.1080/0951192X.2022.2078514.

DİĞER ESERLER:

- Yaşar, H., Çağıl, G., Torkul, O., ve Şişçi, M. (2021). Cylinder Pressure Prediction of an HCCI engine using deep learning. *Chinese Journal of Mechanical Engineering*, 34, 1-8.
- Hızıroğlu, A., Şişçi, M., Cebeci, H. I., ve Seymen, Ö. F. (2018). An Empirical Assessment of Customer Lifetime Value Models within Data Mining. (2018). An Empirical Assessment of Customer Lifetime Value Models within Data Mining. *Baltic Journal of Modern Computing*, 6(4), 434-448., Doi: bjmc.2018.6.4.08 (Yayın No: 4687265)

- Torkul, O., Şişçi, M. ve Şerifoğlu M. A. (2021). Prediction of Biochemical Oxygen Demand (BOD5) in Wastewater Treatment Plant Based on Fuzzy Rough Set Theory and Machine Learning: An Industrial Case Study. *International Conference on Interdisciplinary Applications of Artificial Intelligence 2021 (ICIDAAI-2021)*, Yalova, Turkey.
- Kiraz A., Açıkgöz, N. ve Şişçi, M. (2019). A Fuzzy-Logic-Based Approach to EFQM Model for Performance Improvement. *10th International Symposium on Intelligent Manufacturing and Service Systems*, Sakarya, Turkey.
- Boran, S., Selvi, İ. H., Demircioğlu Diren D. ve Şişçi M. (2019). Analyzing the Out of Control Signal in Multivariate Processes with Fuzzy Rough Set Theory and Machine Learning. *10th International Symposium on Intelligent Manufacturing and Service Systems*, Sakarya, Turkey.
- Knowledge Management and Digital Transformation Power, Bölüm adı:(Machine Learning As A Tool For Achieving Digital Transformation) (2022)., Şişçi M., Torkul, Y. E. ve Selvi, İ. H., Efe Academy Publishing, Editör: Torkul Orhan, Tunacan Tuğba, Basım sayısı:1, Sayfa Sayısı 268, ISBN:978-625-6995-16-1, İngilizce (Bilimsel Kitap).
- Yapay Zeka Dijital Sistemler ve Uygulamaları, Bölüm adı:(Mühendislikte Yeni Eğilimler ve Akıllı Şehirler) (2021)., Torkul, O., Şişçi, M. ve Torkul, Y. E., Papatya Bilim, Basım sayısı:1, Sayfa Sayısı 528, ISBN:978-605-9594-88-2, Türkçe(Bilimsel Kitap).
- Mühendislikte Yapay Zeka ve Uygulamaları 3, Bölüm adı:(Microsoft Azure Machine Learning Studio ile Regresyon Uygulamaları) (2020)., Torkul O. ve Şişçi, M., Sakarya Üniversitesi Kütüphanesi, Editör: Sevinç GÜLSEÇEN, Mehmet Melih İNAL, Orhan TORKUL, İhsan Hakan SELVİ, Çiğdem EROL, Gültekin ÇAĞIL, Zerrin AYVAZ REİS, Muhammed Kürşad UÇAR, Basım sayısı:1, ISBN:978-605-2238-24-0, Türkçe(Bilimsel Kitap).
- Mühendislikte Yapay Zeka ve Uygulamaları, Bölüm adı:(R Programlama Dili ile Kaba Kümeleme Uygulamaları) (2018)., Sencer S., Torkul, O., Şişçi, M. ve Turgay, T., Sakarya Üniversitesi Kütüphanesi Yayınevi, Editör:Sevinç Gülseçen, Alpaslan Fırlalı, Orhan Torkul, Muhammed Kürşad Uçar, Basım sayısı:1, Sayfa Sayısı 30, ISBN:978-605-2238-08-0, İngilizce(Bilimsel Kitap).
- Esnek Hesaplama: İşletme ve Ekonomide Uygulamaları, Bölüm adı:(Gelişmekte Olan Birleşik Esnek Hesaplama Teknolojileri) (2017)., Hızıroğlu A., Kiraz A., Cebeci H. İ., Taşkın H., Selvi İ. H., Seçkin Codal, K., İpek, M. ve Şişçi M., Sakarya Üniversitesi, Editör:R. A. Aliev, B. Fazlollahi, R. R. Aliev, Basım sayısı:1, Sayfa Sayısı 444, ISBN:978-605-4735-80-8, Türkçe(Kitap Tercümesi).