

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI

**ULTRASON TARAMALARINDAN FETÜS HAREKETLERİNİN TESPİTİ İÇİN
YENİ DERİN ÖĐRENME MODELLERİ GELİŐTİRİLMESİ**

DOKTORA TEZİ

MUSA TURKAN

TEZ DANIŐMANI

DOÇ. DR. EMRE DANDIL

BİLECİK, 2025

10710642

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI

**ULTRASON TARAMALARINDAN FETÜS HAREKETLERİNİN TESPİTİ İÇİN
YENİ DERİN ÖĐRENME MODELLERİ GELİŐTİRİLMESİ**

DOKTORA TEZİ

MUSA TURKAN

TEZ DANIŐMANI

DOĐ. DR. EMRE DANDIL

BİLECİK, 2025

10710642

BEYAN

“Ultrason Taramalarından Fetüs Hareketlerinin Tespiti İçin Yeni Derin Öğrenme Modelleri Geliştirilmesi” adlı Doktora Tezinin hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.			
DESTEK ALINMIŞTIR	<input type="checkbox"/>	DESTEK ALINMAMIŞTIR	<input checked="" type="checkbox"/>
Destek alındı ise;			
Destekleyen kurum;			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Diğer;.....			
ETİK KURUL onayı var ise;			
ETİK KURUL karar tarih/sayı:		Kütahya Sağlık Bilimleri Üniversitesi Klinik Olmayan Araştırmalar Etik Kurulu 08.07.2021 / 2021/12-07	

Musa TURKAN

Tarih

.../.../2025

İmza

ÖN SÖZ

Fetüs hareketlerinin takip edilmesi sağlıklı giden bir gebelik sürecinde önemli bir parametre olup, anne karnında fetal hareketlerin azalması veya hiç olmaması ciddi fetüs risklerinin bir belirtisi olarak değerlendirilebilir. Fetüs hareketlerinde genel hareketler sağlıklı bir sürecin habercisi iken, endişe verici hareketler ise fetüs sağlığının olumsuz olduğunun belirtisi olabilir. Ultrason ile görüntüleme vücuda ilaç verilmemesi, radyasyon yaymaması sebebiyle, fetüs görüntülenmesinde yoğun olarak kullanılmaktadır. Ultrason görüntüleme, fetüs hareketlerinin bebeğin sağlık durumuyla ilgili bilgi veren önemli bir parametre olmasından dolayı, hamilelik takibinde sıklıkla kullanılan bir görüntüleme yöntemidir. Fetüs ultrason görüntülerinin incelenmesi ve değerlendirilmesi ile bazı hastalıklar erkenden teşhis edilebilmektedir. Gerçek zamanlı ultrason görüntüleme kullanılarak fetüs hareketleri gözlemlenebilir. Fetüs video ve görüntülerinden, fetüs hareketlerinin tanımlanması ve takibi genellikle zor ve karmaşık bir süreç içermektedir. Bu tez çalışma kapsamında önerilen yeni derin öğrenme mimarileri ile fetüs videolarının hareketlerinin etiketlenmesi, fetüs görüntüsünde anatomik yapıların belirlenmesi, genel fetüs hareketlerinin tanınması ve video üzerinde takibi ile fetüs yörüngesinin çıkarımı sağlanmıştır. Tez çalışması sürecinde aynı zamanda, fetüs dokularının hareketlerinin belirlendiği yeni bir video veri seti oluşturulmuştur. İnsan gözlemi ile tespit edilemeyecek bazı hareket tiplerinin, önerilen yeni derin öğrenme modelleri ile sınıflandırılması sağlanarak, teşhis ve tedavide ikincil bir araç olarak kullanılabilmesi araştırılmıştır.

Ömrüm boyunca destekleriyle her daim yanımda olan anne ve babama, akademik çalışmalarında desteğini her zaman yakından hissettiğim tez danışmanım sayın Doç. Dr. Emre DANDIL'a, veri toplama konusunda bize destek veren Bursa Şehir Hastanesi'nden sayın Doç. Dr. Furkan Ertürk URFALI'ya, KSBÜ'den Doç. Dr. Mehmet KORKMAZ'a teşekkür ederim. Tez çalışmalarım sırasında iş ortamında bana bu fırsatı veren BŞEÜ Bilgi İşlem Daire Başkanı Murat FİDAN'a, şube müdürüm sayın Öğr. Gör. Yusuf MUŞTU'ya, uzun çalışma dönemlerinde yanımda olup bana sabreden, her zaman destek veren değerli eşim Berrin TURKAN'a teşekkür ederim.

Musa TURKAN

2025

ÖZET

ULTRASON TARAMALARINDAN FETÜS HAREKETLERİNİN TESPİTİ İÇİN YENİ DERİN ÖĞRENME MODELLERİ GELİŞTİRİLMESİ

Tıbbi görüntülerin ve videoların bilgisayar destekli algoritmalar ile analiz edilmesi, hastalıkların teşhis ve tedavisinde önemli faydalar sağlamaktadır. Özellikle son yıllarda, derin öğrenme algoritmalarındaki artan gelişmeler, medikal verilerin işlenmesinde hız, performans ve donanım ihtiyacı gibi konularda sürekli iyileşme sağlamıştır. İleri derece uzmanlık gerektirebilen medikal verilerin inceleme işlemlerinin derin öğrenme algoritmalarıyla yapılması, hekimlerin karar verme aşamasında yardımcı bir araç olarak yaygın olarak kullanılmaya başlamıştır. Ultrason (US) videolarında fetüsün hareketlerinin izlenmesi ve anatomik yapıların tanınması bebek sağlığının değerlendirilmesinde önemli bir parametredir. Fetüs hareketlerinin takip edilmesi sağlıklı giden bir gebelik sürecinde önemli bir parametre olup, anne karnında fetal hareketlerin azalması veya hiç olmaması ciddi fetüs risklerinin bir belirtisi olarak değerlendirilebilir.

Bu tez çalışmasında, ultrason videolarından fetüs hareketlerinin analizi ve değerlendirilmesi için Kütahya Sağlık Bilimleri Üniversitesi Evliya Çelebi Eğitim ve Araştırma Hastanesi'nden toplanan ultrason videoları ile bir veri seti oluşturulmuştur. Tez çalışmasında, öncelikle fetal ultrason videolarını kullanarak fetüsün anatomik yapılarını tanımak ve hareketlerini tespit etmek için YOLO ve uzun kısa-süreli bellek (LSTM) algoritmalarına dayanan hibrit bir derin öğrenme yöntemi önerilmiştir. Bu aşamada, fetüsün anatomik yapıları belirlenmek ve hareketlerini takip etmek için ultrason videoları uzman radyologlar eşliğinde etiketlenmiştir. Deneysel analizlerde fetüsün kalp, baş ve gövde gibi anatomik yapılarının hareketleri takip edilerek hareket yörünge örüntüleri çıkarılmıştır. Son adımda ise iki boyutlu düzleme dönüştürülen hareket örüntüleri kullanılarak LSTM derin öğrenme algoritması ile fetal anatomik yapıların tespiti ve sınıflandırılması sağlanmıştır.

Ultrason videolarındaki fetal hareketlerin otomatik olarak sınıflandırılması, fetal iyilik halinin değerlendirilmesi ve hamilelik sırasında olası komplikasyonların tespit edilmesi için kritik öneme sahiptir. Tez çalışmasının ikinci aşamasında ise, ultrason video dizilerindeki fetal hareketlerin sınıflandırılmasını iyileştirmek için bir dikkat (attention) mekanizması ve evrimsel sinir ağlarını (CNN) içeren yeni bir derin öğrenme modeli olan FetalMovNet mimarisi geliştirilmiştir. Model, özellik çıkarımı için CNN ve uzamsal-zamansal örüntüleri yakalamak için bir dikkat mekanizmasını entegre ederek fetal hareketlerin sınıflandırma performansını önemli ölçüde artırmaktadır. FetalMovNet'i değerlendirmek için, yedi farklı

anatomik yapıya (kafa, gövde, kol, el, kalp, bacak ve ayak) ait ultrasondaki fetal hareketleri içeren verisetinde deneysel çalışmalar yürütülmüştür. Elde edilen sonuçlar, FetalMovNet'in 0.9887 doğruluk (accuracy), 0.9871 kesinlik (precision), 0.9910 geri çağırma (recall) ve 0.9891 F1-skoru (F1-score) elde ederek gelişmiş CNN ve CNN-LSTM mimarilerinden daha iyi performans başardığını göstermektedir. Ablasyon çalışmaları, FetalMovNet'in CNN için 0.9471 ve CNN-LSTM için 0.9543 ile karşılaştırıldığında, 0.9957'lik bir eğri altı alan (AUC) puanı elde etmesiyle dikkat mekanizmasının etkinliğini doğrulamaktadır. Önerilen FetalMovNet modeli, gerçek zamanlı fetal hareket izleme için sağlam ve klinik olarak uygulanabilir bir araç sağlayarak manuel değerlendirme ihtiyacını azaltmaktadır ve doğum öncesi bakımı iyileştirme potansiyeline sahiptir.

Tez kapsamında önerilen derin öğrenme modellerinin boyutu küçük olduğundan sınıflandırma ve tespit süresi oldukça düşüktür ve gerçek zamanlı ultrason görüntülerinin değerlendirilmesi için uygun olduğu değerlendirilmektedir. Çalışmada kullanılan FetalMovNet derin öğrenme modelinin bir diğer önemli avantajı, düşük çözünürlüklü ultrason görüntülerinde bile yüksek performans göstermesidir. Tezde, hareket anomalilerinin sınıflandırılması ve dokulara özel hareket yörüngelerinin ayrıntılı incelenmesi, fetüste nörolojik rahatsızlıkların erken teşhisine yönelik umut vaat eden bir yaklaşım olarak değerlendirilmiştir. Gelecekte bu yaklaşımın, fetüste anormal hareket tespitinde kullanılarak hamilelikte tanı süreçlerinde önemli bir rol oynayabileceği değerlendirilmektedir.

Anahtar Kelimeler: Fetüs, Fetal Hareket Tanıma, Ultrason (US), Derin Öğrenme, Dikkat Mekanizması.

ABSTRACT

DEVELOPMENT OF NOVEL DEEP LEARNING MODELS FOR FETAL MOVEMENT DETECTION IN ULTRASOUND SCANS

The analysis of medical images and videos with computer-based algorithms offers significant advantages in the diagnosis and treatment of diseases. Especially in recent years, advances in deep learning algorithms have led to continuous improvements in the processing of medical data in terms of speed, performance and hardware requirements. The use of deep learning algorithms to analyze highly specialized medical data has become widely used as a tool to help doctors make decisions. Tracking fetal movement and recognizing anatomical structures in ultrasound (US) videos is an important parameter in assessing infant health. Monitoring fetal movement is an important parameter in a healthy pregnancy, and reduced or absent fetal movement in the womb can be considered a sign of serious fetal risk.

In this thesis, a dataset of ultrasound videos collected from Kütahya University of Health Sciences Evliya Çelebi Training and Research Hospital was created for the analysis and evaluation of fetal movements from ultrasound videos. First, a hybrid deep learning method based on YOLO and Long Short-Term Memory (LSTM) algorithms is proposed to recognize fetal anatomical structures and detect fetal movements using fetal ultrasound videos. In this phase, ultrasound videos are labelled by expert radiologists to identify fetal anatomical structures and track fetal movements. In the experimental analysis, the movements of fetal anatomical structures such as the heart, head and body are tracked and movement trajectory patterns are extracted. In the final step, the LSTM deep learning algorithm is used to detect and classify the fetal anatomical structures using the motion patterns converted to a two-dimensional (2D) plane.

Automatic classification of fetal movements in ultrasound videos is crucial for assessing fetal well-being and detecting potential complications during pregnancy. In the second phase of the thesis, a new deep learning model, FetalMovNet, is developed to improve the classification of fetal movements in ultrasound video sequences by incorporating an attention mechanism and convolutional neural networks (CNN). By integrating CNNs for feature extraction and an attention mechanism to capture spatio-temporal patterns, the model significantly improves the classification performance of fetal movements. To evaluate FetalMovNet, experimental studies are conducted on a dataset of ultrasound fetal movements of seven different anatomical structures (head, body, arm, hand, heart, leg and foot). The results show that FetalMovNet outperforms advanced CNN and CNN-LSTM architectures, achieving accuracy of 0.9887,

precision of 0.9871, recall of 0.9910 and F1-score of 0.9891. Ablation studies confirm the effectiveness of the attention mechanism, with FetalMovNet achieving an area under the curve (AUC) of 0.9957, compared to 0.9471 for CNN and 0.9543 for CNN-LSTM. The proposed FetalMovNet model provides a robust and clinically applicable tool for real-time fetal movement tracking, reducing the need for manual assessment and has the potential to improve prenatal care.

Due to the small size of the deep learning models proposed in this thesis, the classification and detection time is very short and they are considered suitable for the evaluation of real-time ultrasound images. Another important advantage of the FetalMovNet deep learning model used in the study is its high performance even on low resolution ultrasound images. In this thesis, the classification of motion abnormalities and the detailed analysis of tissue-specific movement trajectories are considered as a promising approach for the early diagnosis of neurological disorders in the fetus. In the future, this approach may play an important role in the diagnostic process during pregnancy by being used to detect abnormal fetal movement.

Keywords: Fetus, Fetal Movement Recognition, Ultrasound (US), Deep Learning, Attention Mechanism.

İÇİNDEKİLER

	Sayfa
ÖN SÖZ.....	i
ÖZET.....	ii
ABSTRACT.....	iv
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	ix
KISALTMALAR LİSTESİ.....	xi
1. GİRİŞ.....	1
1.1. Tezin Amacı.....	5
1.2. Hipotez ve Araştırma Sorusu	5
1.3. Tezin Katkıları.....	5
1.4. Tezin Organizasyonu.....	6
2. LİTERATÜR ÇALIŞMASI	9
2.1. Geleneksel Yöntemler ve Makine Öğrenmesi Kullanılarak Önerilen Çalışmalar	10
2.2. Derin Öğrenme Yöntemleri ve Güncel Yaklaşımlar	14
3. VERİSETİ VE ORGANİZASYONU	20
4. ULTRASON TARAMALARINDAN HAREKET YÖRÜNGE VERİLERİ KULLANILARAK DERİN ÖĞRENME İLE FETÜSTE ANATOMİK YAPILARIN TANINMASI.....	22
4.1. Fetal Hareketler	23
4.2. Materyal ve Yöntem	24
4.2.1. YOLO Algoritması (You Only Look Once).....	25
4.2.2. Deep-Sort Algoritması.....	27
4.2.3. Uzun Kısa-Sürelili Bellek (long short-term memory) Derin Sinir Ağları.....	28
4.3. Deneysel Çalışmalar	31

5. ULTRASON TARAMALARINDAN FETAL HAREKETLERİN SINIFLANDIRILMASI İÇİN DİKKAT MEKANİZMASI TABANLI YENİ BİR DERİN ÖĞRENME MODELİ GELİŞTİRİLMESİ	41
5.1. Materyal ve Yöntem	41
5.1.1. Dikkat Mekanizması (Attention Mechanism)	44
5.2. Evrişimli Ağ (Convolution network).....	46
5.3. Tam Bağlı Ağ	47
5.4. Deneysel Çalışmalar ve Bulgular	48
6. TARTIŞMA	57
7. SONUÇLAR	65
KAYNAKÇA	69

TABLULAR LİSTESİ

	Sayfa
Tablo 4.1. Farklı fetal hareket tipleri (S. Liu vd., 2019: 261)	23
Tablo 4.2. Anlık motor hareketleri özellikleri (Karadavut, 2011: 47)	23
Tablo 4.3. Doğrulama seti için YOLOv5 modeli ile elde edilen mAP, P, R ve F1 gibi performans metrik sonuçlarının karşılaştırılması	34
Tablo 5.1. Verisetinde eğitim ve test kümelerindeki ultrason tarama/video sayıları	48
Tablo 5.2. FetalMovNet mimarisinde kullanılan temel hiperparametreler ve değerleri	49
Tablo 5.3. Önerilen FetalMovNet mimarisinde katman yapısı ve detayları	50
Tablo 5.4. Önerilen FetalMovNet ve diğer yöntemlerin performanslarının metriklerle karşılaştırılması	54
Tablo 6.1. FetalMovNet modelinin sonuçlarının, fetal anatomik yapıların tanınması ve sınıflandırılması için daha önce önerilen mevcut çalışmalarla karşılaştırılması	61

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1. WoS üzerinde “Fetal movement” anahtar kelimesi için yoğunluk haritası.....	9
Şekil 2.2. WoS üzerinde “fetus deep learning” araması için anahtar kelime ilişkilerinin yoğunluk haritası.....	10
Şekil 3.1. Veri setindeki her anatomik yapı için ultrason videolarındaki hareketleri ve değişiklikleri temsil eden kareler (frame)	21
Şekil 4.1. Kullanılan derin öğrenme modelinin genel mimarisi	25
Şekil 4.2. YOLOv5 derin öğrenme modelinin üç alt bileşenden oluşan mimarisi	27
Şekil 4.3. Yinelemeli bir sinir ağı hücresinin yapısı	28
Şekil 4.4. RNN mimarisinde zincir yapısı	29
Şekil 4.5. RNN yapısında her bir modülün tek bir katman içermesi	29
Şekil 4.6. LSTM derin öğrenme ağlarında hücre yapısı	31
Şekil 4.7. Ultrason taramalarındaki fetüse ait anatomik yapıların tanınması için YOLOv5s derin öğrenme mimarisinin 100 epok (tur) boyunca eğitimi sonucunda oluşan performansı.....	32
Şekil 4.8. Fetal ultrason veri kümesinde YOLOv5 yöntemi kullanılarak fetüsün baş, gövde ve kalp gibi bazı anatomik yapılarının tanınması	34
Şekil 4.9. Fetüsün anatomik yapılarının hareket yörüngelerinin örüntülerinin çıkarılması.....	35
Şekil 4.10. Normalize edilmiş konum noktalarının hareket yörüngeleri için x ve y eksen değerleri (kalp ve kafa).	36
Şekil 4.11. 2B sinyal dizisine dönüştürülen yörünge verilerinin sınıflandırılması için kullanılan LSTM ağının yapısı.....	37
Şekil 4.12. Farklı ultrason çerçevelerinde fetal kalbin anatomik yapısının hareketlerindeki değişiklikler.....	38
Şekil 4.13. (a) YOLOv5 kullanılarak fetüsün video görüntüsünden kalbin anatomik yapısının tanınması ve sınırlayıcı kutunun oluşturulması, (b) Kalbin x eksen için hareket yörüngesi konum verilerinin normalleştirilmesi	38
Şekil 4.14. LSTM ağ eğitiminde ve doğrulamasında kayıp fonksiyonu değişimi.....	39

Şekil 4.15. (a) Eğitim verileri için önerilen LSTM ağının fetal kalp hareketlerinden anatomik yapı tahmini, (b) doğrulama verileri için önerilen LSTM ağının fetal kalp hareketlerinden anatomik yapı tahmini.....	40
Şekil 5.1. Fetal hareketlerin sınıflandırılması için önerilen FetalMovNet derin öğrenme ağının mimarisi.....	42
Şekil 5.2. Dikkat mekanizmasında kullanılan, Q, K, V matrislerinin oluşturulması.....	45
Şekil 5.3. Dikkat bloğu iç yapısı ve işleyiş mekanizması	46
Şekil 5.4. FetalMovNet modelinde kullanılan conv katmanı.....	47
Şekil 5.5. Çıkışta kullanılan sınıflandırma katmanı	47
Şekil 5.6. Önerilen FetalMovNet mimarisinin eğitimi sırasında 50 epok için (a) kayıp ve (b) validasyon doğruluğu değerlerinin değişimi.	51
Şekil 5.7. FetalMovNet mimarisinin Conv4 katmanının çıkışında öğrenilen filtre kalıpları ..	52
Şekil 5.8. Fetüsün anatomik yapılarının hareketlerinin sınıflandırılması için testte modeller kullanılarak elde edilen karışıklık matrisi sonuçları. (a) tipik bir CNN mimarisi, (b) CNN-LSTM mimarisi ve (c) önerilen FetalMovNet mimarisi	53
Şekil 5.9. Fetal anatomik yapıların sınıflandırılması için test setindeki her bir anatomik yapı için (a) tipik CNN, (b) CNN-LSTM ve (c) önerilen FetalMovNet mimarilerinin ROC eğrileri ve AUC skorları	55
Şekil 6.1. Önerilen FetalMovNet mimarisi kullanılarak test setindeki yanlış sınıflandırılmış fetal hareketlerin ardışık çerçevelerinin değerlendirilmesi	59
Şekil 6.2. Grad-CAM ile ultrason sekanslarında kafa, kalp, gövde, kol, bacak, el ve ayak gibi fetal anatomik yapılar için FetalMovNet'in özellik çıktılarının ısı haritası.....	63

KISALTMALAR LİSTESİ

3B	: Üç Boyutlu (3D)
2B	: İki Boyutlu (2D)
AE	: Auto Encoder (Otomatik Kodlayıcı)
AUC	: Area Under the Curve (Eğri Altındaki Alan)
CNN	: Convolutional Neural Network (Evrşimsel Sinir Ağı)
CPU	: Central Process Unit (Merkezi İşlem Birimi)
CSV	: Comma-Separated Values (Virgülle Ayrılan Değerler)
CONV	: Convolution (Evrşim)
CSPNET	: Cross Stage Partial Network (Çapraz Aşamalı Kısmi Ağ)
CPC-S	: Science Proceedings Citation Index
ED	: End-Diastole
ES	: End Systole
ESA	: Evrşimsel Sinir Ağı
FCL	: Fully Connected Layer (Tam Bağlı Katman)
FCN	: Fully Connected Network (Tam Bağlı Ağ)
FetalMovNet	: Önerilen Yeni Derin Öğrenme Mimarisi
FP	: False Postive (Yanlış Pozitif)
FN	: False Negative (Yanlış Negatif)
FPN	: Feature Pyramid Network (Özellik Piramit Ağı)
FUIQA	: Fetus Ultrasonic Image Quality Assesment (Fetüs Ultrason Görüntü Kalitesi Değerlendirmesi)
GAN	: Generative Adversarial Network (Çekişmeli Üretici Ağ)
GPU	: Graphics Process Unit (Grafik İşlem Birimi)
DVM	: Destek Vektör Makinesi
HC18	: Head Circumference (Kafa Çevresi)

HD	:High Definition (Yüksek Çözünürlük)
HOG	: Histogram of Gradients (Gradyanların Histogramı)
HOF	: Histogram of Optic Flow (Optik Akış Histogramı)
LSTM	: Long Short-Term Memory (Uzun Kısa-Süreli Bellek Ağı)
IoU	: Intersection over Union (Kesişim Bölü Birleşim)
(Q, K, V)	: Query, Key, Value (Sorgu, Anahtar, Değer)
MBH	: Motion Boundary Histogram (Hareket Sınırı Histogramı)
MHz	:Mega Hertz
MR	: Manyetik Rezonans
MSE	: Mean Square Error (Ortalama Kare Hatası)
NST	: Non Stres Test (Stres Olmayan Test)
ROC	: Receiver Operating Characteristic (Alicı Çalışma Karakteristiği)
ROI	: Region of Interest (İlgilenilen Bölge)
R-CNN	: Regional-Convolutional Neural Network (Bölgesel-Evrişimsel Sinir Ağı)
RNN	: Recurrent Neural Network (Yinelenen Sinir Ağı)
RMSprop	: Root Mean Square Propagation
PANet	: Path Aggregation Network
SMH	: Spontaneous Human Motion (Anlık İnsan Hareketleri)
SSD	: Single Shot Detector (Tek Aşamalı Algılayıcı)
SCI	: Science Citation Index (Bilimsel Atıf İndeksi)
SSCI	: Social Sciences Citation Index (Sosyal Bilimsel Atıf İndeksi)
TP	: True Positive (Doğru Pozitif)
TN	: True Negative (Doğru Negatif)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
UHD	: Ultra High Definition (Yüksek Çözünürlük)

US	: Ultrason
Val Box	: Validation Box (Doğrulama)
Val Objectness	: Validation Objectness
VGG16	: Visual Geometry Group 16
YAML	: İnsan dostu bir veri serileştirme yöntemi
YOLO	: You Only Look Once (Sadece Bir Kere Bak)
YSA	:Yapay Sinir Ağları
WoS	: Web of Science

1. GİRİŞ

Fetüste meydana gelen anormal gelişmeler, özellikle son yıllarda birçok ülke için doğuma yakın ölümlerde artışa neden olmaktadır (Salomon vd., 2011). Son yirmi yılda yaklaşık 48 milyon bebek ölü doğmuştur ve çoğu düşük gelirli ülkelerde olmak üzere her yıl ortalama 2 milyon bebek ölü doğmaktadır (UN, 2020). Bebek ölümlerinin çoğunun hayat kurtarıcı önlemler ve kaliteli sağlık hizmetleri ile önlenebileceği düşünülmektedir. Ayrıca, dünya genelinde her yıl bebeklerin %3 - %6'sı ciddi bir kusurla doğmaktadır (CDC, 2022). Buna ek olarak, çocuk doğurma ve gebeliğe bağlı anne ölümleri 100.000 canlı doğumda yaklaşık 211'dir (WHO, 2019). Bu nedenle, fetüste meydana gelen bir anormalliğin erken dönemde tespit edilmesi hem anne hem de fetüs sağlığı açısından çok önemlidir.

Fetüs hareketlerinin takip edilmesi uzun yıllardır bilinen bir işlemdir. Fetal hareketlerin azalması veya hiç olmaması ciddi fetüs risklerinin bir belirtisi olabilir (You vd., 2017: 494). Fetüsün nasıl hareket ettiği ve gebelik sırasında nicel ve nitel hareket desenleri hakkında bilgi son birkaç on yılda mevcut hale gelmiştir. Fetüs hareketlerinin takip edilmesi sağlıklı giden bir gebelik sürecinde önemli bir parametredir. Fetüs hareketleri genel hareketler ve endişeye sebep olabilecek hareketler olarak sınıflandırılabilir. Genel hareketler sağlıklı bir sürecin habercisi iken endişe verici hareketler fetüs sağlığının olumsuz durumda olduğunun belirtisi olabilir (Bai, 2016). Gerçek zamanlı ultrason (US), doğal ortamlarında sağlıklı ve bozulmamış fetüslerde kapsamlı motor repertuarının kalite değerlendirmesine izin vermiştir. Bu bilgi, büyüme kısıtlı fetüslerde, erken doğuma yönelik fetüslerde ve kromozomal bozukluklarda fetal hareketlerin karakterize edilmesini sağlamıştır (Velazquez ve Rayburn, 2002: 993).

Fetal hareketlerin değerlendirilmesi, doğum öncesi bakımın önemli bir yönüdür ve fetal sağlık ve iyilik halinin önemli bir göstergesi olarak hizmet eder. Fetal hareketler tipik olarak 15. gebelik haftasında fark edilebilir hale gelir (Lüchinger vd., 2008: 191). Bu hareketler tekmeler, yuvarlanmalar ve çırpınmaları içerebilir ve fetüsün yaşına ve aktivite düzeyine bağlı olarak güç ve sıklık açısından değişiklik gösterir. Fetal hareketlerin anormal örüntüleri veya azalmış sıklığı, fetal sıkıntı, büyüme kısıtlamaları ve hatta ölü doğum gibi potansiyel komplikasyonlara işaret edebilir (Turner vd., 2021: e215071). Geleneksel olarak fetal hareketlerin izlenmesi, doğası gereği öznel ve değişkenliğe açık yöntemler olan anne algısına ve sağlık uzmanlarının manuel (el yordamı) gözlemine dayanmaktadır.

Fetüs hareketlerinin artması her zaman iyi bir durum değildir. Bazı durumlarda artan fetüs hareketleri istenmeyen durumların işareti olabilir. Bu durumda hangi tür hareketlerin istenmeyen durum olduğunun tespit edilmesi zor bir işlemdir. Hamile kadınlar gebelik boyunca

karmaşık bir dizi fetal hareket deseni hissederler. Birçok faktör kadınların anne obezitesi, anne davranışı ve ruh hali dahil fetal hareket algısını etkilemektedir. Ölü doğum öncesi azalan fetal hareketler, plasental yetmezliği yansıtan ilerleyici olma eğilimindedir ve tıbbi yardım alma ve olumsuz sonuçları önlemek için müdahale etme fırsatı verir. Aşırı hareketin bir bölümü ciddi fetal rahatsızlıkların bir işareti olabilir. Gebelerin bunu anlaması zor olduğundan, bazı vakalarda müdahale edilmesi gecikebilir (Whitehead vd., 2019: 1). Fetüsün hareketleri fetüsün nörolojik olarak sağlıklı gelişip gelişmediği hakkında bilgi verebilir. Bu hareketlerin uygun şekilde tanımlanabilmesi ve takip edilmesi birçok araştırma için yol gösterici veri oluşturabilir. Ayrıca, rahimdeki nörolojik gelişmenin kilometre taşlarını takip etmek için fetüs hareketlerinin takip edilebileceği belirtilmiştir (Birnholz vd., 1978: 537). Bununla birlikte, standartlaştırılmış kafa, karın ve femoral gibi anatomik yapıların görüntü düzlemlerinin alınması değişken görüntü kalitesi nedeniyle zordur (Ahmed ve Noble, 2016: 157). Bu nedenle, iki boyutlu (2B) ultrason taramaları yoluyla fetal biyometrik ölçümlerin elde edilmesi fetal izleme için çok önemlidir.

Ultrason görüntüleme tekniği de tıbbi uygulamalarda en çok kullanılan teşhis ve tedavi yöntemlerinden biridir (Huang vd., 2018). Özellikle doğum öncesi görüntülemelerde, dünyanın çoğu yerinde, göreceli güvenliği, ucuz oluşu, kolay kullanılması sebebiyle tercih edilir (Saha, 2014). Ultrason görüntüleme cihazlarının ucuz olması bu yöntemin yaygın olarak tıbbi görüntülemelerde kullanılmasına imkân sağlamıştır. Fetüs görüntüleme işlemleri ve hamilelik takibinde de ultrason yöntemiyle görüntüleme yoğun olarak kullanılan bir yöntemdir. Fetüste anatomik nesne (örneğin fetal standart düzlem, organlar, dokular vb.) lokalizasyonu, bölütleme işlemleri, klinik teşhis için bir ön koşul olarak kabul edilmiştir (S. Liu vd., 2019: 261). Gerçek zamanlı ultrason görüntüleme kullanılarak fetüs hareketleri gözlemlenebilir. İki boyutlu görüntüler, fetal toraks (karın ve boyun arası) ve karın eksenine boyunca anne karnı üzerine bir ultrason dönüştürücüsünün yerleştirilmesiyle üretilir. 5-30 dakikalık bir gözlem süresinin genellikle yeterli olduğu düşünülmektedir. Fetal hareketlerin sıklığı, yoğunluğu ve süresi, hareketlerin anne tarafından algısı ile ilişkilidir. Ultrason muayenesi sırasında gözlenen belirli daha kısa süreli veya yoğunluktaki hareketler genellikle algılanmaz (Velazquez ve Rayburn, 2002: 993).

Ultrason görüntüleri uygun görüntü işleme teknikleriyle birleştirildiğinde, görüntüler daha verimli bir şekilde işlenebilir ve profesyonellere tanı ve tedavide yardımcı olabilir. Ultrason teknolojisinin ortaya çıkışı, fetal hareketleri gerçek zamanlı olarak görselleştirme ve izleme yeteneğini büyük ölçüde geliştirmiştir, ancak bu hareketlerin yorumlanması büyük

ölçüde manuel olmaya devam etmektedir ve hem zaman alıcı hem de insan hatasına eğilimli olabilen uzman analizi gerektirmektedir.

Fetal hareketlerin tespiti, takibi ve sınıflandırılması için daha önce önerilmiş farklı çalışmalar olduğu görülmektedir. Bu çalışmalar genellikle hekimlerin karar verme süreçlerini kolaylaştırıcı araç ve yöntemleri içermektedir. Örneğin fetüste çeşitli organ ve anatomik yapıların belirlenmesi (Yaqub vd., 2012: 1555), baş çevresi ve bacak uzunluğu gibi bazı biyometrik ölçümlerin yapılması (Sobhaninia vd., 2019: 6545), fetüste standart düzlemin belirlenmesi (Lei vd., 2014: 85; Yu vd., 2017: 874) çalışmaları bunlardan bazılarıdır. Ayrıca, uzmanlara karar vermelerinde yardımcı olmak için ultrason görüntülerinin sınıflandırılmasını sağlayan çalışmalar (Ishikawa vd., 2019: 181; Malathi ve Shanthi, 2009: 341) da bulunmaktadır. Örneğin, Ishikawa ve arkadaşları (Ishikawa vd., 2019: 181) fetal pozisyonu tahmin etmek için baş, gövde, bacaklar ve diğer parçalar gibi fetal parçaların tanınmasını ve sınıflandırılmasını önermiştir.

Derin öğrenme algoritmaları geliştikçe, hareket tanımada kullanımları yaygınlaşmıştır. Hareket sınıflandırma için birçok derin öğrenme modeli önerilmiştir. CNN (Convolutional Neural Network) ve dikkat (attention) mekanizmaları insan hareketlerini sınıflandırmak ve videodan belirli hareketleri tespit etmek için kullanılmaktadır (Vosta ve Yow, 2023; J. Zhang ve Liu, 2008: 81). Öte yandan, CNN ve LSTM (Long Short Term Memory) kombinasyonunun insan eylemi tanıma gibi video hareket tanıma görevleri için etkili bir şekilde çalıştığı da gösterilmiştir (Majd ve Safabakhsh, 2020: 224). Derin öğrenmeden elde edilen performans artışı, eğitim için kullanılan büyük veri kümelerine bağlıdır. Fetal hareket algılama ve sınıflandırma için yüksek kaliteli veri kümelerinin oluşturulması bu alanda önemli bir süreçtir. Medikal alanda herkese açık birçok veri kümesi olmasına rağmen, mevcut fetal veri kümeleri çok sınırlıdır ve bu kısıt, bu alandaki derin öğrenme uygulamalarının geliştirilmesindeki ana darboğazlardan biridir (S. Liu vd., 2019: 261). Bu nedenle, fetüs ve fetal hareketlerle açıklanmış standartlaştırılmış ultrason görüntülerinden oluşan büyük veri kümelerine ihtiyaç vardır. Ayrıca derin öğrenme algoritmaları daha yüksek performans, daha az donanım tüketimi ve daha doğru sonuçlar ile her geçen gün gelişmeye devam etmektedir. Özellikle hareketlerin sınıflandırılması için geliştirilen derin öğrenme modellerinde nesnel hareket yörüngeleri ile takip edilebilmektedir. Bu durumda hareket eden nesnenin her karede değişen konumu hareket hakkında bilgi verebilmektedir. Bu şekilde derin öğrenme yöntemleri ile birleştirilen ve hareket yörüngelerini kullanarak sınıflandırma yapan çalışmalar mevcuttur (Roy ve Bilodeau, 2019: 65; L. Wang vd., 2015: 4305). Ayrıca eklemlerin hareket yörüngeleri 2B görüntüye bir veri

olarak eklenerek insan hareketleri tanımlanabilmektedir (P. Wang vd., 2016: 102). Ayrıca, nesnelerin yörünge bilgileri hareketin zamansal bilgisini temsil etmek için kullanılabilir (Shi vd., 2015: 1).

Gelişen teknolojiyle, farklı derin öğrenme yöntemlerinin uygulanması ile yüksek performanslı sonuçlar veren çalışmalar bulunmasına rağmen bu alanda hala ilerleme kaydedilmesi gereken pek çok konu bulunmaktadır. Ultrason görüntüleri üzerinde yapılan çalışmalar genel olarak (i) fetal standart düzlem tespiti, (ii) anatomik yapı analizi ve (iii) biyometri parametre tahmini çalışmaları olarak sınıflandırılabilir (Fiorentino vd., 2023: 102629). Bu görevlere bakıldığında, fetüste doku hareketlerinin tanınmasına yönelik çalışmalara ihtiyaç duyulduğu anlaşılmaktadır.

Fetal videolardaki hareketlerin değerlendirilmesi ve sınıflandırılması için önerilen önceki çalışmaların sınırlı olduğu gözlemlenmiştir. Fetüs üzerine yapılan önceki çalışmalarda fetüsün klinik ölçümleri, fetal dokuların bölütlenmesi (segmentasyonu) ve fetal görüntülerin kalitesinin değerlendirilmesi önerilmiştir. Ayrıca fetal baş çevresini ölçmek, fetal lateral ventrikülleri tespit etmek ve 2B fetal görüntülerden fetal anatomiyi tespit etmek ve ölçmek için yöntemler geliştirilmiştir (G. Carneiro vd., 2008: 1342; X. Chen vd., 2020: 526; van den Heuvel vd., 2018: e0200412; Wu vd., 2017: 1336). Öte yandan, ultrason görüntülerine dayalı görevler için, hareketsiz görüntüleri incelemek yerine videonun doğrudan analizinin daha başarılı olduğu gösterilmiştir (Ouyang vd., 2020: 252).

Bu tez çalışmasında:

- Öncelikle geliştirilen derin öğrenme modellerinin eğitilmesi ve performanslarının değerlendirilmesi için fetüse ait anatomik yapılarının hareketlerinden oluşan bir yeni veri seti oluşturulmuştur.
- Fetal hareketlerin yörünge bilgilerinin anatomik yapılar göre farklı desen örüntüleri oluşturduğu bilinmektedir. Bu nedenle, fetüsteki anatomik yapıların hareket yörüngeleri elde edilerek farklı hareket türlerinin sınıflandırılması sağlanabilir. Tez çalışmasının ilk aşamasında, hareket yörüngeleri kullanılarak fetal anatomik yapıların tespiti ve tanınması için YOLO ve LSTM yöntemlerine dayalı bir derin öğrenme yaklaşımı önerilmiştir.
- İkinci aşamada, fetal hareket sınıflandırması için dikkat ve CNN tabanlı yeni bir derin öğrenme modeli olan FetalMovNet önerilmiştir. Bu model, hem uzamsal hem de

zamansal bilgileri etkili bir şekilde işleyerek CNN ve CNN-LSTM gibi mevcut son güncel yöntemlere kıyasla daha yüksek performans sunmaktadır.

1.1. Tezin Amacı

Fetüs hareketlerinin bebeğin gelişiminde önemli ipuçları veren, hatta bazı hastalıkların erken teşhisinde de kullanılabilir hareketler olduğu pek çok akademik çalışmada gösterilmiştir(Çakır vd., 2022: 139; Sarı ve Çiğdem, 2013: 40; Türker, 2023: 31). Bu tez çalışması “*Fetüs hareketlerinin derin öğrenme yoluyla tanınması mümkün olabilir mi?*” sorusuyla başlayan araştırmalarla ortaya çıkmıştır.

Bu tez çalışmasında, fetüs ultrason videolarından yeni bir veri setinin hazırlanması ve bu veri setinde fetal ultrason videolarını ve yörüngelerini kullanarak fetüsün anatomik yapılarının tanınması ve hareketlerinin tespit edilmesi ve sınıflandırılması amaçlanmıştır.

1.2. Hipotez ve Araştırma Sorusu

“*Fetüs hareketlerini sınıflandırabilen yeni derin öğrenme modelleri geliştirilmesi fetüs iyilik halinin değerlendirmesinde uzmanlara yardımcı olacak bir çıkarım sağlayabilir*” hipotezi tez kapsamında üzerinde durulan konu olmuştur. Bir diğer incelenen konu ise “*Videolarda sıralı kareler üzerinde dikkat mekanizmasının uygulanması fetüste hareket sınıflandırma modelinin başarımına katkı sağlayabilir*” hipotezi ile dikkat katmanının ultrason hareketlerinin sınıflandırmasındaki etkisidir.

Tez kapsamında aşağıdaki araştırma sorularından yola çıkılarak araştırmalar yapılmıştır:

- i. Fetüs anatomik yapılarının hareketlerini içeren ve hareketlerin etiketlenebileceği yeni bir video veri seti oluşturulabilir mi?
- ii. Fetal sağlık durumunun analizinde fetal hareketlerden faydalanılabilir mi?
- iii. Fetüs anatomik yapı hareketleri önerilen yeni derin öğrenme yöntemleriyle yeni bir video veri seti kullanılarak sınıflandırılabilir mi?
- iv. Videolardan fetüs hareketlerinin tanınması için derin öğrenme mimarilerinde dikkat katmanının kullanılması başarımı nasıl etkiler?

1.3. Tezin Katkıları

Tez kapsamında yapılan çalışmalarda aşağıdaki katkılar sunulmuştur.

- Çalışmada öncelikle fetüsteki anatomik yapıların hareketlerini içeren ultrason videolarından bir veri seti hazırlanmıştır.

- Hareket yörüngelerini kullanarak fetal anatomik yapıların tespiti ve tanınması için YOLO ve LSTM yöntemlerine dayalı bir derin öğrenme yaklaşımı önerilmiştir.
- Fetal hareket sınıflandırması için dikkat ve CNN tabanlı yeni bir derin öğrenme modeli FetalMovNet önerilmiştir. Bu model, hem uzamsal hem de zamansal bilgileri etkili bir şekilde işleyerek CNN ve CNN-LSTM gibi mevcut son teknoloji yöntemlere kıyasla daha yüksek performans sunmaktadır.
- Önerilen FetalMovNet modeli, dikkat mekanizması sayesinde sıralı ultrason karelerinde yalnızca önemli bölgelere ve hareketlere odaklanarak daha doğru ve güvenilir sınıflandırma sonuçları elde etmektedir. Dikkat mekanizması modelin girişine uygulanan kareler arasındaki değişen alanlara odaklanmayı sağlayarak hareketin sınıflandırılmasına katkı sağlamaktadır. Girişteki her bir karenin diğer karelere göre bir dikkat skorunu hesaplanarak, bu skor sınıflandırmada önemli olan bölümlere odaklanmayı sağlamaktadır.
- FetalMovNet modeli, fetal hareketlerin zamansal özelliklerini göz önünde bulundurarak hareket dizilerindeki kritik örüntüleri yakalayabilmektedir. Bu, özellikle ultrason videolarında sıralı hareketlerin daha doğru bir şekilde anlaşılmasına katkıda bulunmaktadır.

1.4. Tezin Organizasyonu

Bu tez çalışması, ultrason videolarında fetal hareketlerin derin öğrenme yöntemleriyle tanınması ve sınıflandırılması üzerine odaklanmaktadır. Çalışmanın amacı, fetal hareketlerin otomatik olarak izlenebilmesini ve değerlendirilmesini sağlayacak yeni derin öğrenme modelleri geliştirmektir. Tez kapsamında bu amaca uygun bir veri seti de oluşturulmuştur.

Birinci bölümde tezin genel amacı, hipotezi ve araştırma soruları açıklanmaktadır. Fetal hareketlerin izlenmesinin neden önemli olduğu, bu alanda karşılaşılan zorluklar ve derin öğrenme teknolojilerinin bu sorunlara nasıl çözümler sunabileceği tartışılmaktadır. Bu bölümde tezin literatüre katkısı belirtilmiştir ve çalışmanın temel amacının anlaşılması için açıklamalar yapılmıştır.

İkinci bölümde tez konusunda benzer literatürdeki çalışmalar incelenmiştir. Hareket tanıma amacıyla geliştirilen modeller ve fetüsle ilgili yapılan derin öğrenme çalışmaları özetlenmiştir. Geleneksel yöntemler, makine öğrenmesi tabanlı yaklaşımlar ve derin öğrenme yöntemleri detaylı bir şekilde ele alınmıştır. Benzer çalışmalar hakkında bilgi verilmiştir. Fetüs

ultrason görüntüleme konusundaki çalışmalara yer verilmiş ve Web of Science (WoS) üzerinde “fetüs deep learning, action recognition, fetüs movement,” anahtar kelimelerinin bibliyometrik incelemesi yapılmıştır. Daha önce önerilen çalışmalar Geleneksel Yöntemler ve Makine Öğrenmesi Yöntemleri ve Derin Öğrenme yöntemleri olarak iki başlık altında incelenmiştir. “Fetüs movement” anahtar kelimesi ile ilgili çalışmaların kalp hareketleri yoğunluklu çalışmalar olduğu gözlenmiştir. İkinci bölümdeki açıklamalar literatürdeki boşlukları belirlemek ve bu tezin nasıl bir katkı sağladığını göstermek amacıyla hazırlanmıştır. Çalışmalarda kullanılan veri setleri hakkında bilgi verilmiş tez konusu olan veri setine benzer olabilecek veri setleri değerlendirilmiştir. Yapılan incelemelerde fetüs anatomik yapı hareketlerini analiz eden kapsamlı bir çalışmaya rastlanmamıştır. Çalışmaya en çok benzeyen yaklaşımlar kalp hareketlerini analiz etmeye yönelik çalışmalardır. Ayrıca, fetüs anatomik yapı hareketlerini barındıran bir veri setine de rastlanmamıştır.

Üçüncü bölümde çalışmanın temelinde yer alan Kütahya Sağlık Bilimleri Üniversitesi (KSBÜ) Evliya Çelebi Eğitim ve Araştırma Hastanesinden elde edilen ultrason taramaları kullanılarak verisetinin oluşturulması aşamaları anlatılmıştır. Ayrıca, fetüs anatomik yapılarının yörünge bilgilerine bağlı hareket desenlerini çıkarmak için dokuların yörünge bilgilerinden oluşan veriseti de detaylandırılmıştır. Ayrıca, verisetinin eğitimi ve test aşamalarında nasıl kullanıldığı bu bölümde açıklanmıştır. Diğer taraftan, verisetinin toplandığı hastalar, veri setinde kullanılan taramaların alındığı ultrason cihazları ve veriseti ilgili detaylı bilgi verilmiştir. Son olarak, veri ön işleme süreçleri de bu bölümde açıklanmıştır.

Dördüncü bölümde fetal anatomik yapıların tanımlanması ve hareketlerin tespiti için kullanılan yöntemler detaylı bir şekilde açıklanmaktadır. Bu bölümde, fetal anatomik yapıların tespiti ve hareket eden dokuların yörünge değişikliklerine bağlı hareket sınıfını tespit eden altyapı sunulmuştur. Bu amaçla fetüs dokularını tanıyan bir model kullanılarak dokulara ait yörünge bilgileri çıkarılmış ve yörüngeler arasındaki farklılıklar incelenmiştir. Ayrıca, bu bölümde fetal hareketlerin analizinde kullanılan yöntem detaylı olarak sunulmuştur. Ek olarak, fetüse ait anatomik yapılarının, tarama üzerinde tespit edilerek konum bilgilerini kaydetme yöntemiyle hareketlerin sınıflandırılmasına dair deneysel çalışmalar sunulmuştur. Ayrıca, hareket eden organların konum bilgilerinden yörünge verisi ortaya çıkarılarak yörünge verisindeki farklılıklar incelenmiştir.

Beşinci bölüm, çalışmanın en önemli katkısını oluşturan FetalMovNet modelinin tanıtımı ve deneysel sonuçlarının sunulduğu bölümdür. Bu model dikkat mekanizmasını ve CNN (evrişim ağı) katmanlarını kullanan bir derin öğrenme uygulamasıdır. Modelin mimarisi,

dikkat mekanizmasının nasıl entegre edildiği, evrişimli sinir ağlarının (CNN) kullanımı ve tam bağlı katmanların işlevleri detaylı bir şekilde açıklanmaktadır. Ayrıca, modelin performansını değerlendirmek için kullanılan metrikler ve ablasyon çalışmaları da bu bölümde ele alınmaktadır. Deneysel sonuçlar, önerilen modelin fetal hareketleri yüksek doğrulukla sınıflandırabildiğini göstermektedir. Bu bölüm, modelin başarısını ve potansiyel uygulama alanlarını ortaya koymaktadır. Bu bölümde önerilen modelin tipik CNN mimarisine karşılaştırılması ve CNN+LSTM ağıyla karşılaştırılması yapılmıştır. Dikkat mekanizmasının sağladığı ayırt edicilik özelliği ile önerilen modelin daha yüksek başarımlar gösterdiği açıklanmıştır. Tipik CNN, CNN+LSTM ve FetalMovNet modellerinin elde ettiği başarımlar değerleri arasında istatistiksel olarak bir farklılık olup olmadığı incelenmiş bu amaçla modellerin başarımlar sonuçları Wilcoxon yöntemiyle analiz edilerek istatistiksel olarak anlamlı farklılık olduğu açıklanmıştır.

Altıncı bölümde literatürdeki benzer çalışmalarla karşılaştırma yapılmış ve konuyla ilgili tartışmalara yer verilmiştir. Literatürde yapılan çalışmalarda kullanılan yöntemler, kullanılan veri setleri ve başarımlar oranları sunulmuştur. Elde edilen bulgular mevcut çalışmalarla uyumlu mu, yoksa farklılık gösterip göstermediği değerlendirilmiştir. Ayrıca, çalışmanın sınırlılıkları ve bu sınırlamalar nasıl aşılabılır konusunda tartışmalar yapılmıştır. Bu bölümde tez çalışmasının güçlü yanları ve geliştirilmesi gereken yönleri tartışılmıştır. Diğer taraftan, tez kapsamında oluşturulan verisetinden kaynaklanan kısıtlar, model mimarisinden kaynaklanan kısıtlar ortaya koyulmuş gelecekteki çözüm önerileri değerlendirilmiştir.

Son bölümde tez çalışmasının sonuçları sunulmuş, yapılabilecek geliştirmeler önerilmiş ve gelecekteki çalışmalar hakkında değerlendirmeler yapılmıştır. Fetüs hareket veri setlerinin ortaya çıkmasıyla yapılabilecek ilave çalışmalar hakkında öneriler sunulmuştur. Kullanılan yöntemlerin geliştirilmesi gereken yönleri ortaya koyulmuştur. Özellikle, verisetinin genişletilmesi, daha karmaşık modellerin kullanılması ve farklı fetal dokuların incelenmesi gibi konular ele alınmıştır. Ayrıca, bu çalışmanın literatüre ve pratik uygulamalara olan katkıları vurgulanmıştır. Gelecekteki çalışmalar için öneriler sunulmaktadır ve bu alanda yapılacak araştırmaların nasıl bir yol izleyebileceği önerilmektedir. Bu bölüm, çalışmanın hem bilimsel hem de pratik öneminin bir kez daha altını çizmektedir.

olmak üzere ultrason görüntüleri kullanılarak birçok uygulama gerçekleştirilmiştir. Diğer taraftan, ultrason görüntülerinden veya videolarından tümör, lezyonların tespit edilmesi temel ultrason görüntü işleme görevlerinden biridir. Görüntülerdeki tümör ve lezyonların tespiti ve segmentasyonu, iyi huylu ve kötü huylu tümörlerin birbirinden ayrılabilmesi için ultrason görüntüleri destek sağlayabilir. Fetüste anatomik nesne (fetal standart düzlem, organlar, dokular) lokalizasyonu, segmentasyon işlemleri, klinik teşhis için bir ön koşul olarak kabul edilmiştir (S. Liu vd., 2019: 261).

Ultrason görüntüleriyle çalışmak diğer tıbbi görüntüleme görüntüleriyle çalışmaktan daha karmaşık bir işlemdir. Çünkü ultrason görüntülerinde çözünürlük çok düşüktür, çok fazla gürültü bulunmaktadır ve görsel bir işaret yoktur. Bu sebeple ultrason görüntülerinin incelenmesi için alana uygun algoritmaların kullanılması gerekmektedir (Saha, 2014). Erişilebilir olan veri kümeleri derin öğrenme modellerini eğitmek için çok uygun şekilde etiketlenmiş değildir. Bu zorlukların üstesinden gelmek için gerçek ultrason görüntüleri yerine, fetüs fantomu kullanılarak oluşturulan veriseti de sunulmuştur (Prabakaran vd., 2023). Büyük verisetlerinin sınıflandırılması, görüntü düzeyinde etiketleme, segmentasyon için piksel düzeyinde etiketleme yapılması oldukça fazla zaman alan işlemlerdir. Çalışmalarda oluşturulan verisetleri genellikle fetüs ölçümleri yapmak, fetüs dokularını bölümlenmek, fetüs görüntülerinin kalitesini ölçmek amacıyla kullanılmıştır. 2B görüntüden oluşan veriseti kullanılarak fetal baş çevresinin ölçülmesi, fetal lateral ventriküllerin ölçülmesi (beyin gelişiminin ölçülmesindeki iç beyin omurilik sıvısı), fetal anatomilerin tespiti ve ölçümünü yapan yöntemler geliştirilmiştir (G. Carneiro vd., 2008: 1342; X. Chen vd., 2020: 526; Fiorentino vd., 2023: 102629; van den Heuvel vd., 2018: e0200412; Wu vd., 2017: 1336).

Fetal görüntü veri setlerinin yüksek kaliteli olarak oluşturulması bu alandaki önemli bir işlemdir. Özellikle fetüste veriseti oluşturmak için önerilmiş bazı çalışmalar bulunmaktadır. Bunların birisinde, fetal baş çevresinin otomatik ölçümü için HC18 (Head Circumference) veriseti oluşturulmuştur ve görüntüler deneyimli bir uzman tarafından etiketlenmiştir (van den Heuvel vd., 2018: e0200412). Başka bir çalışmada (Burgos-Artizzu vd., 2020: 10200), 6 farklı anatomik yapının sınıflandırma etiketlerine sahip bir veriseti oluşturulmuştur. En yaygın olarak kullanılan fetal anatomik düzlemler (karın, beyin, uyluk kemiği, göğüs kafesi, anne rahim ağzı vd.), olarak etiketlenmiştir. Çalışmadaki veriseti bir web sitesinde açık erişimli olarak paylaşılmıştır.

Geleneksel makine öğrenmesi, veri sınıflarını ayırt edilmesinde özelliklerin hesaplanmasını içermektedir. Bu özellikler daha sonra bir sınıflandırıcıyı eğitmek ve test etmek

için kullanılır. Ultrason için kullanılan yaygın özellik türleri morfolojik, (örneğin lezyon alanı veya çevresi), dokusal özellikler, frekans bilgileri temelli ve parametre uydurma bilgilerine dayanmaktadır. Genellikle çok sayıda aday özellik hesaplanır ve daha sonra özellikleri daha küçük bir kompozit kümede birleştirmek ve en iyi özellikleri seçmek için bir özellik seçimi algoritması uygulanır. Bu süreçte, verisetleri için genellikle boyut azaltma uygulanır. Rastgele orman (random forest), destek vektör makineleri (DVM) ve yapay sinir ağları (YSA) en çok kullanılan geleneksel makine öğrenmesi tabanlı yöntemlerdir (Brattain vd., 2018: 786). Geleneksel yöntemleri pek çoğu belli kurallar üzerinde çalışan ikili sınıflandırma ağaçları kullanılarak yapılmıştır. Geleneksel yöntemler belli başarımlar elde etse de çeşitli sebepler oluşan gürültülere karşı hassastırlar.

Fetal hareketlerin grafiğini çizmek için birtakım çalışmalar yapılmış olsa da bu hareketlerin miktarı, ideal sayısı, ne zaman sayılması gerektiği gibi hususlarda genel bir çerçeve tanımlanmamıştır (Velazquez ve Rayburn, 2002: 993). Bekedam ve arkadaşları (Bekedam vd., 1985: 155) gelişme geriliği olan fetüsün motor davranışlarını incelemiştir. Yapılan çalışmada gelişim geriliği olan fetüslerde hareket sayısı ve genliğinin daha az olduğu gözlemlenmiştir. İzole bacak hareketleri, seğirme hareketlerinin şaşırtıcı derecede azaldığı tespit edilmiştir. Bir diğer çalışmada, Gustavo Carneiro ve diğerleri (Gustavo Carneiro vd., 2007: 571) kısıtlı olasılıklı güçlendirici ağaç algoritması kullanılarak ultrason görüntülerinde fetal ölçümlerin otomatik yapılmasını sağlayan bir yöntem önermişlerdir. Kafa çevresi, karın çevresi ve femur gibi ölçümleri yapılabilmesini sağlayan bu yöntem uzmanların doğruluğuna yakın bir çözüm elde edilmiştir. G. Carneiro ve diğerleri (G. Carneiro vd., 2008: 1342) diğer çalışmalarında, ultrason görüntülerinde fetal anatomik yapıları tespit eden ve ölçen bir yöntem sunmuşlardır. Çalışmada, kısıtlı olasılık artırıcı ağaç kullanarak fetal görüntülerde anatominin sınıflandırmasını ve ölçümünü yapmışlardır. Çalışmada, kafa, karın, kol üst bölgesi, kalça ve tüm beden olmak üzere beş farklı sınıf etiketi ile sınıflandırma ve ölçüm yapılmıştır.

Yaqub ve diğerleri (Yaqub vd., 2012: 1555) fetüsün lokal beyin yapılarını tespit etmek için rasgele karar ağacı yöntemini kullanmışlardır. Derin öğrenme kavramının henüz ortaya çıkmadığı dönemde yüksek başarımla beyin yapılarını lokalize edebilmişlerdir. Bir diğer çalışmada, Rahmatullah ve diğerleri (Rahmatullah vd., 2011: 35) AdaBoost öğrenme algoritmasını kullanarak standart fetal düzlemini tespit etmişlerdir. Fetal biyometri ölçümü için üç boyutlu (3B) fetal ultrason görüntüleriyle çalışmışlardır. Warrick ve diğerleri (Warrick vd., 2010: 1865) uterus basıncı ve kalp atış hızı hareketlerine bağlı olarak fetüsün oksijen eksikliği

durumunu tahmin eden bir yöntem önermişlerdir. Kalp atış hızı ve uterus basıncı verilerini kullanan bir DVM ile sınıflandırma yapmışlardır.

Feng ve diğerleri (Feng vd., 2009: 2488), 3B ultrason görüntüleri kullanarak fetüs yüzünü otomatik tanıyan bir yöntem önermişlerdir. Çalışmada, fetal yüzü üzerinde tespit edilen farklı nokta işaretleri kullanılarak yüz belirleme yapılmıştır. Bir diğer çalışmada, Copeland ve Chiang (Copeland ve Chiang, 2012: 341) fetal kalp dalgalarını kullanarak fetüs sağlık durumun tahmin etmeye çalışmışlardır. Çalışmada, veri madenciliği yöntemleri ve istatistiksel yöntemler kullanarak sınıflandırma yapmışlardır.

Rahmatullah ve diğerleri (Rahmatullah vd., 2012: 354) makine öğrenme teknikleri kullanarak fetal ultrason görüntülerinden anatomik yer belirleme işlemi yapmışlardır. Görüntü modülü, özellik çıkarma modülü, öğrenme algoritması ve dedektör modülünden oluşan 4 kademeli bir algoritma sunmuşlardır. Mide ve göbek bağı anatomik yapılarını içeren pozitif örnekler manuel olarak ultrason görüntülerinden kesilerek eğitim amacıyla kullanılmıştır. Negatif örnek oluşturmak için manuel bir şekilde göbek ve mide yapısını içeren bölümler görüntülerden kaldırılmıştır. Öğrenme algoritması olarak AdaBoost algoritması kullanılmıştır.

Gorthi ve diğerleri (Gorthi vd., 2009: 6222) riskli gebelikleri tespit etmek için regresyon ağacı algoritması kullanmışlardır. Klinik değerlerin alt ve üst sınırları tanımlanarak kural bazlı bir sınıflandırma yapmışlardır. Rutin klinik parametreleri, laboratuvar parametreleri, fetal görüntüleme parametreleri ve ultrason doopler parametreleri belirlenerek önerilen algoritma için kurallar çalıştırılmıştır. Diğer bir çalışmada ise, Lei ve arkadaşları (Lei vd., 2014: 85) fetüs görüntülerinde düzlemi belirlemek için bir DVM algoritması geliştirmişlerdir.

Fetüs dokularının hareketlerini sınıflandıracak bir model mevcut hareket tanıma algoritmalarından ilham alarak tasarlanabilir. Wrobel ve diğerleri (Wróbel vd., 2014) doopler sinyallerini kullanarak fetüs hareketlerini tespit eden bir algoritma geliştirdiler. Geliştirilen algoritma ile doopler sinyalleri kullanılarak anne tarafından hissedilen hareketlerin büyük bir bölümünün tespit edilmesi sağlanmıştır.

Surlea ve diğerleri fetal hareketleri sınıflandırma için, optik akış histogramlarını bir sinir ağını eğitmek için kullandılar. Fetüsün hareket edip etmediğini sınıflandıran bir ağ geliştirdiler. Doku hareketlerine değil fetüsün genel hareketlerine odaklanmışlardır ve başarıları oldukça düşüktür(Surlea vd., 2011: 1).

Tang ve Chen (Tang ve Chen, 2009: 648) ultrason fetüs görüntülerinde fetal anatomik yapıların tespitini amaçlayan bir model geliştirmişlerdir. Sınıflandırma modelinde DVM, geri

yayımlı ağı tabanlı YSA ve radyal temelli YSA kullanılmıştır. Bir diğere alıřmada, Malathi ve Shanthi (Malathi ve Shanthi, 2009: 341), bir geriye yayılım ağı tabanlı YSA ve öklit mesafesi kullanarak plasenta anomalilerini tespit eden bir alıřma yapmışlardır. alıřmada normal plasenta ve anormal plasenta olarak sınıflandırma yapılmıştır. Bir diğere alıřmada, Garcia-Canadilla ve diğere leri (Garcia-Canadilla vd., 2020: 363) fetal kardiyografide makine öğrenmesi yöntemlerini inceleyen bir derleme makale yayınlamışlardır. alıřmada fetüsün istemsiz hareketleri, kalp organının ok küçük olması ve fetal kardiyografide uzman eksikliği sebepleriyle fetal kardiyografi deęerlendirmesinin zor olduęu belirtilmiştir. Bu incelemede fetüs ultrason kardiyografisi konusundaki alıřmaların tek bir makinadan alınan görüntülerle yapıldığı belirtilmiştir. Daha fazla eřitlilikte makinalardan alınan görüntülerle alıřmaların daha ileri seviyede faydalı sonuçlar elde edebileceęi deęerlendirilmiştir.

2.2. Derin Öğrenme Yöntemleri ve Güncel Yaklaşımlar

Ultrasonik görüntü analizinde kullanılan derin öğrenme teknikleri pek ok farklı görevi icra etmek için kullanılır. Sınıflandırma, tespit etme, bölütleme, biyometrik ölçümler, nesne konumu belirleme gibi birok amaçla derin öğrenme modelleri kullanılır. Sınıflandırma görevi bir anatomik yapının veya dokunun diğere llerinden ayırt edilmesini saęlayan en temel derin öğrenme işlevlerinden biridir. Doku, fetüs gibi farklı organların ultrasonik görüntülerini sınıflandırmak için de önerilen derin öğrenme tabanlı yöntemler bulunmaktadır. Fetüs ultrason görüntülerinin incelenmesinde de başarıyı arttırmak, daha faydalı destekler saęlamak üzere pek ok derin öğrenme modeli geliştirilmiştir. Mimari olarak farklılıklar gösteren bu modeller farklı fetüs görevlerinde kullanılmışlardır. Bu bölümde derin öğrenme yöntemleriyle fetüs görüntüleri üzerinde yapılan alıřmalar sunulmuştur. Özellikle fetal hareketlere odaklanan alıřmalara yer verilmiştir. Bunun yanında fetüs ile ilgili görüntü işleme, segmentasyon, sınıflandırma modelleri de incelenmiştir.

Derin öğrenme algoritmalarının yaygınlaşmasıyla birlikte geleneksel algoritmalarla birlikte derin öğrenme algoritmaları hareket tanımak amacıyla da kullanılmıştır. Hareket sınıflandırma amacıyla oluşturulmuş ok sayıda derin öğrenme modeli gösterilmiştir. İnsan hareketlerini tanıma, trafik hareketlerini inceleme, hayvanların hareketlerini inceleme, topluluk hareketleri gibi pek ok farklı konuda hareket tanıma modelleri ortaya çıkmıştır (Burgos-Artizzu vd., 2020: 10200; Looney vd., 2017: 279; Ravishankar vd., 2016: 779; Sinclair vd., 2018: 714). Derin öğrenme yaklaşımlarında, özellikle hareket tanımak için Evriřimli Sinir Ağları (CNN), Tekrarlayan Sinir Ağları (RNN) ve bunların türevleri yaygın olarak kullanılmaktadır. CNN, görüntü tabanlı analizlerde başarılı olup ultrason görüntülerinden

özellik çıkarmada etkili olmaktadır. RNN ve özellikle Uzun Kısa Süreli Bellek (LSTM) ağları ise zaman serisi verilerinde güçlü bir hafızaya sahip olduğu için fetal hareketlerin zamansal analizi açısından avantaj sağlayabilir. Derin sinir ağları, ham veriden orta ve üst düzey soyut özellikleri doğrudan öğrenebilmeleri sebebiyle belirgin avantaja sahiptirler. Derin sinir ağları görüntüler için bir tahmin etiketi oluşturmak amacıyla doğrudan kullanılabilir (Liu vd., 2019). Fetüs görüntüleme işleminde önemli bir iş adımı da biyometrik ölçümler ve teşhis amacıyla standart düzlemin belirlenmesidir. Son yıllarda derin öğrenme teknikleri kullanarak cenin standart düzleminin belirlenmesi işlemi birçok çalışmaya konu olmaktadır (S. Liu vd., 2019: 261).

Video tabanlı hareket tanıma çalışmalarında, iki temel yaklaşım öne çıkmaktadır: Çerçeve bazlı analiz ve hareket temelli analiz. Çerçeve bazlı analizde, videodan belirli kareler çıkarılarak görüntü sınıflandırma yöntemleri uygulanmaktadır. Hareket temelli analizde ise hareket bilgisi doğrudan modele entegre edilmektedir. Hareket tanıma yönelik olarak son yıllarda pek çok model sunulmuştur. Bu modellerde 3B-CNN, CNN-RNN ve dikkat-tabanlı modeller olarak sunulmuştur. İnsan hareketlerinin sınıflandırılması, videodan belli hareketlerin tanınması amacıyla CNN ve dikkat mekanizmaları kullanılmaktadır (Vosta ve Yow, 2023; J. Zhang ve Liu, 2008: 81; J. Zhang ve Liu, 2023: 421).

Derin öğrenme kullanılarak video özelliği tanıma işlemi, derin ağlar içeren yöntemlerdir. Derin öğrenme yöntemlerinin sorunu büyük miktarda etiketli veri gerektirmesidir. Derin öğrenme yöntemleri zaman boyutu ile uzay boyutu arasındaki yerleşik farkı göz ardı eder. Evrişimli ağlara video verilerini uygularken zaman boyutunu özellik kanalı olarak ele alır (L. Wang vd., 2015: 4305). Son teknoloji video tanıma yöntemleri oldukça başarımlı elde yüksek edebilmektedir. Hareket modelleri, kare çiftleri arasındaki hareket bilgilerini analiz ederek veya birden çok karedeki (nesne yörüngeleri) hareket bilgilerini analiz ederek çıkarılabilir. İlk yaklaşım, kısa menzilli modellerin çıkarılması için uygundur, ikinci kategori ise yörünge bilgisi mevcut olduğunda uzun menzilli modellerin çıkarılmasına yardımcı olur. İki'den fazla sayıda pek çok karedeki yörünge bilgilerinin değerlendirilmesi uzun süreli hareketlerin tanınabilmesine imkan verir (Nawaz vd., 2014: 1016).

Hamilelikte ilk üç aylık dönemde ultrason görüntülerinden elde edilen ölçümlerin riskli hamilelik durumunu tahmin etmekte kullanıldığı gösterilmiştir (Looney vd., 2017: 279). Ultrason görüntüleri kullanılarak kritik anatomik yapıların tespiti, fetüs hareketlerinin takip edilmesi hamilelik sürecinin izlenmesi sağlanabilir. Fetüs hareketleri, aktif olmayan bir kalp atış durumunun tespit edilmesinde kullanıldığı için önemli bir işlemdir (Wróbel vd., 2014).

Fetal kalp hareketi kalp hastalıklarının tespiti ve değerlendirilmesi için önemli bir göstergedir. Patra ve Noble (Patra ve Noble, 2019: 1761) çalışmalarında fetal kalp hareketlerinin incelenmesi ve değerlendirilmesine yönelik çalışma yapmıştır. Bu amaçla VGG-16 ağı ve LSTM kullanılarak görüntüler analiz edilmiştir. Bir diğer çalışmada, Dozen ve diğerleri (Dozen vd., 2020: 1526) fetal kardiyak ultrason videolarında karıncık bölgesinin segmentasyonunu yapmışlardır. Fetal kalp atışları ile dinamik olarak şekil değiştiren ve küçük olan kalp alt yapılarını tespit etmişlerdir. Zaman serisi bilgisi ve özel bölge bilgisini kullanarak çalışan bir ağ sunmuşlardır. Kaliappan ve arkadaşları (Kaliappan vd., 2023: 1692) fetal kalp hızıyla ilgili özellikler kullanılarak fetal sağlık durumu tahmini yapan bir model geliştirilmişlerdir. Kalp hızına ait veriler Cardiotocogram prosedürüyle elde edilen verilerden oluşturulmuştur. Yine bir diğer çalışmada, Kuzu ve Santur (Kuzu ve Santur, 2023: 2471) hazırladıkları kardiyografi verisetini kullanarak fetal sağlığın sınıflandırılmasını sağlayan bir çalışma yapmışlardır. Fetal sağlık durumunu normal, patolojik ve şüpheli olarak sınıflandırmışlardır. Non Stres Test (NST) cihazının dahili belleğindeki sayısal verilerin etiketlenmesiyle oluşturulan verisetinde eğitilen bir model ile sınıflandırma yapmışlardır.

Ishikawa ve diğerleri (Ishikawa vd., 2019: 181) cenin pozisyonunu tahmin etmek için ultrason görüntülerinde CNN kullanılarak fetal parçaların tanınması ve sınıflandırılmasına dayalı bir yöntem önermişlerdir. Çalışmada, fetal parçalar baş, gövde, bacak ve diğer parçalar olarak sınıflandırılmıştır. Her bir ultrason karesinde sınırlayıcı kutuların merkezi merkezlerin yörüngesi elde edilecek şekilde hesaplanarak, yörünge olarak fetüsün konumu elde edilmiştir.

van den Heuvel ve diğerleri (van den Heuvel vd., 2019: 773) kaynakları sınırlı olabilecek ülkelerde ultrason görüntülerinin kullanılarak fetüste baş çevresinin ölçülmesini sağlayan bir derin öğrenme yöntemi önermişlerdir. VGG-Net ağından ilham alınarak eğitilen bir CNN ağı fetüs kafasını tanımak için eğitilmiştir. İkinci olarak, başka bir sinir ağı baş çevresini her karede tespit edilen organ için hesaplamak üzere eğitilmiştir. Sonuçlar ağın başarılı şekilde tahmin yapabildiğini göstermiştir. Bir diğer çalışmada, van Merendok ve diğerleri (van Merendonk vd., 2017: e2012) kaba motor hareketlerin fetal davranış modellerini tanımlamak ve sınıflandırmak için bir çalışma yapmışlardır. 12 kategoride belirgin davranış kalıpları belirlemişlerdir. Çalışmada, fetüsün kol bacak gibi temel uzuvlarının olduğu 10. hafta ile 18. hafta arasındaki fetüsler incelenmiştir. Ayrıca, fetüs görüntüleme sırasında yaşanan zorlukların üstesinden gelmek için bir sistematik gözlem ve analiz prosedürü oluşturmuşlardır. 10-11, 12-13, 14-15, 16-17 haftalık fetüsler 20 dakikalık videolarla kaydedilmiş ve davranışları incelenmiştir.

Fetal düzlemlerin ultrason görüntülerinde doğru şekilde alınması biyometrik ölçümlerin doğru yapılabilmesi ve çeşitli teşhislerin yapılabilmesi için önemli bir husustur. Chen ve diğerleri (H. Chen vd., 2015: 507) karma bir ağ ultrason kullanarak standart düzlemini algılayan bir yöntem önermişlerdir. Bu amaçla amacıyla konumsal bilgiyi birleştirmek için önceden eğitilmiş RNN tabanlı derin öğrenme modeli kullanmışlardır.

Ultrason görüntü kalitesi cenin karın çevresinin ölçümleri için çok önemlidir. Wu ve diğerleri (Wu vd., 2017: 1336) iki aşamalı bir cenin ultrasonik görüntü kalitesi değerlendirme (FUIQA – Fetus Ultrasonic Image Quality Assessment) şeması önermişlerdir. RoI'yi (Region of Interest – İlgi Bölgesi) lokalize etmek için bir CNN kullanmışlardır. RoI'ye dayanarak, cenin karın standart düzlemini sınıflandırmak için başka bir CNN kullanmışlardır. Performansı arttırmak için, araştırmacılar yerel faz analizi ve görüntü kırpma gibi çeşitli veri geliştirme stratejileri kullanmışlardır. Diğer taraftan, fetüs büyümesi ve sağlığının takip edilmesinde baş çevresinin ölçülmesi önemli bir veridir. Sobhaninia ve diğerleri (Sobhaninia vd., 2019: 6545) çalışmalarında, fetüs biyometrik özelliklerini ölçmek amacıyla CNN tabanlı bir derin öğrenme ağı kullanmışlardır.

Jang ve arkadaşları (Jang vd., 2017), çalışmalarında bir ultrason görüntüsünden görüntü bölümlerini ana anatomik yapılara sınıflandırmak için özel olarak tasarlanmış bir CNN mimarisini kullanmışlardır. Cenin karın düzlemini (yani standart düzlem) temel alarak, cenin karın çevresi ölçümünü Hough dönüşümüne dayanan bir elips tespit yöntemiyle hesaplamışlardır.

Gao ve diğerleri (Gao vd., 2016), büyük ölçekli doğal görüntülerden öğrenilmiş özelliklerin, cenin anatomik yapısının çok etiketli sınıflandırılması vasıtasıyla küçük ultrasonik cenin görüntülerine aktarılabilceğini keşfetmişlerdir. Çalışmada, önceden doğal görüntülerin bulunduğu büyük veri setleriyle (ImageNet) eğitilmiş bir ağ ile eğitime başlamanın küçük ölçekli ultrason görüntüleriyle eğitilen ağlara göre daha başarılı olduğu görülmüştür.

Cenin kalbinin lokasyonu ve kalple ilgili sınıflandırmalar doğuştan gelen kalp rahatsızlıklarının tespit edilebilmesi için çok önemlidir. Cenin kalbinin küçük boyutları sebebiyle bu sınıflandırmalar zor bir görevdir. Bu sorunları çözmek için Sundaresan ve diğerleri (Sundaresan vd., 2017: 671), çözümü anlamsal bir bölütleme sorunu olarak ortaya koymuşlardır. Kalbin tespit edilmesi ve kardiyak görüntülerinin sınıflandırılması işlemi tek bir adımda gerçekleştirmek için tam bağlı bir CNN kullanmışlardır. Ultrason görüntüleri bu sinir ağına uygulanarak sınıflandırma sağlanmıştır.

Hamilelik takibinde ultrason videolarından biyometrik ölçümler yapmak kritik öneme sahiptir. Wu ve diğerleri (Wu vd., 2017: 1336) çalışmalarında gebelik muayenelerinde uygun olmayan ultrason tarama işlemi sonucunda ortaya çıkan ölçüm hatalarını engellemek için ultrason görüntüsünün kalitesini ölçen bir hesaplama şeması geliştirilmişlerdir. İki derin CNN ağı kullanılarak fetüs ultrason görüntüsünde ilgilenilen bölgenin tespit edilmesi sağlanmıştır. Diğer taraftan, Van Sloun ve diğerleri (van Sloun vd., 2020: 829) yaptıkları çalışmada ultrason damar görüntülerini yüksek çözünürlüklü olarak elde etmeyi sağlayan bir derin öğrenme ağı kullanmışlardır. Böylece, ultrason damar görüntüleri daha yüksek çözünürlüğe dönüştürülebilmektedir.

Ultrason sinyallerinin incelenen nesneye uygun açıda ve pürüzler olmadan uygulanması için dalga yayan aygıtın dikkatli kullanılması gerekmektedir. Ancak yine de görüntülenmek istenen nesnenin yapısı gereği pürüzler olmakta ve görüntüde gürültüler oluşmaktadır. Song ve diğerleri (Song vd., 2019: 102633) seyrek gösterim ve çoklu özellik birleştirmeye dayalı bir çözünürlük iyileştirme algoritması geliştirmişlerdir. Fetüs görüntülerindeki gürültünün giderilmesi ve daha yüksek çözünürlüklü bir görüntü elde edilmesini sağlamışlardır.

Looney ve diğerleri (Looney vd., 2017) ilk üç aylık dönemde 3B plasenta görüntülerinin segmentasyonunu yapmak için derin öğrenme teknikleri kullanmışlardır. Çalışmada, derin bir CNN ağını, DeepMedic algoritması yarı otomatik yöntem olan rastgele gezgin (random walker) metodunun çıktılarını kullanarak eğitilmiştir. Eğitim için kullanılan görüntü sayısı az olmasına rağmen dikkat çekici derecede başarılı sonuçlar elde edilmiştir.

Gebelikte 2B ultrason muayeneleri sırasında fetal standart tarama düzleminin tanımlanması ve yorumlanması oldukça karmaşık görevlerdir. Baumgartner ve diğerleri (Baumgartner vd., 2017: 2204) fetal standart tarama düzlemlerinin gerçek zamanlı algılanması için derin öğrenme kullanmışlardır. SonoNet adını verdikleri CNN tabanlı bir ağ ile ultrason sinyallerini kullanarak standart fetüs görüntülerini elde etmişlerdir. Önerilen mimari kullanılarak, 2B ultrason sinyallerinden 13 farklı fetal standart görünümü otomatik olarak algılamışlardır. Derin öğrenme tabanlı önerilen bir diğer çalışmada, Sinclair ve diğerleri (Sinclair vd., 2018: 714) tam bağlı CNN kullanarak ultrason görüntülerinde fetüs kafa bölgesinin ölçümünü yapmışlardır. Çalışmada, uzman seviyesinde başarımlı doğruluğu elde etmişlerdir.

Yaqub ve diğerleri (Yaqub vd., 2017: 2925) fetüste olası beyin anormalliklerinin tespitine yardımcı olmak için derin öğrenme yöntemi önermişlerdir. Çalışmada, fetal beyne ait ultrason görüntülerinin doğru bir şekilde elde edildiğini ve gerekli klinik standartları

karşılığını otomatik olarak tespit eden bir sistem geliştirmişlerdir. Bu amaçla, fetal beyin doğru lokalizasyonu, ilgilenilen yapıların bulunduğu bölgenin tespiti ve düzlemi doğrulamayı sağlayan bölgelerdeki akustik deseni tanıma işlemi olmak üzere üç aşamada sorunu incelemişlerdir:

Chen ve diğerleri (X. Chen vd., 2020: 526) fetüste 2B ultrason görüntülerinden yan kalp karıncıklarını tespit eden ve ölçen derin öğrenme tabanlı bir yöntem sunmuşlardır. Çalışmada, yan karıncık görüntüsü piksel bazlı segmentasyon elde etmek için derin sinir ağı eğitilmiştir. Daha sonra santimetre başına piksel sayısını daha önce belirlenmiş olan bilgiler ışığında morfolojik işlemlerle hesaplamışlardır. Yapılan deneyler manuel ölçümlere göre daha başarılı sonuçlar elde edilebildiğini göstermişlerdir.

Arnaout ve diğerleri (Arnaout vd., 2020) çalışmalarında fetüste doğuştan gelen kalp rahatsızlıklarını tespit etmek için ultrason görüntülerinden yararlandıkları bir derin öğrenme yöntemi sunmuşlardır. Çalışmada, 18 - 24 haftalık fetüslerden ekokardiyogram ve ultrason görüntüleri eğitim amacıyla kullanılmıştır. Sonuç olarak, kardiyak ölçümler normal ve anormal kalpler için verilen ölçümlerle ilişkilendirilmiştir. Bir diğer çalışmada, Plotka ve diğerleri (Plotka vd., 2023: 101182) fetüste anatomik yapıların ölçülmesi yoluyla fetal ağırlığın tahmin edilmesini sağlayan bir model geliştirmişlerdir. Çalışmada, derin öğrenme tahminleri, farklı uzmanlık düzeylerine sahip 6 insan okuyucu tarafından yapılan test setindeki manuel ölçümlerle karşılaştırılmıştır. Uzmanların ölçümleriyle derin öğrenme modelinin tahminleri arasında farkı %2.5 olarak hesaplanmıştır.

Literatür çalışmaları incelendiğinde, kullanılan derin öğrenme mimarilerinde belli dokuların tanınması, doku büyüklüklerine göre ağırlık tahmin edilmesi, kalp hareketlerine odaklanan çalışmalar bulunmaktadır. Ayrıca, fetüs ultrason taramaları üzerinde hareket tanıma için yapılan çalışmalarda çoğunlukla CNN tabanlı mimariler kullanıldığı görülmektedir. Ancak, literatürde fetüse ait anatomik yapı hareketlerinin ultrason videolarından sınıflandırıldığı bir çalışmayla karşılaşılmamıştır. Bu durum tez çalışmasının orijinalliğini gösteren bir sonuçtur. Dolayısıyla, tez kapsamında yapılan çalışmalar fetüs anatomik yapılarının hareketlerine odaklanması bakımından literatürdeki boşluğa katkı sağlamaktadır. Diğer taraftan, fetüs dokularının hareketlerini içeren bir veri seti de oluşturulması tezin literatüre bir diğer katkısıdır.

3. VERİSETİ VE ORGANİZASYONU

Derin öğrenme uygulamalarında orijinal veri seti kullanımı önemlidir. Literatürde daha önceki çalışmalarda fetüsün birçok anatomik yapısının hareketlerini tespit etmek veya sınıflandırmak için ultrason videolarından oluşturulmuş veri kümesine rastlanmamıştır. Tez kapsamında fetal hareket sınıflandırması için yedi farklı anatomik yapının hareket kareleri ultrason videoları kullanılarak bir veriseti oluşturulmuştur. Veriseti Kütahya Evliya Çelebi Eğitim ve Araştırma Hastanesi'nden sağlanan ultrason videolarından oluşturulmuştur. Fetal ultrason görüntüleri, yaşları 21 ile 40 arası değişen 105 sağlıklı hamile kadından elde edilmiştir. Ultrason görüntüleri 16 hafta ve 23 haftalık fetüslerden Mart 2021 ve Nisan 2024 arasında toplanmıştır. Çalışmanın yürütülmesinde etik açıdan bir sakınca olmadığı Kütahya Sağlık Bilimleri Üniversitesi Klinik Olmayan Araştırmalar Etik Kurulu'nun 08.07.2021 tarih ve 2021/12-07 sayı numarası ile onaylanmıştır. Diğer taraftan, tüm gönüllü hamileler bilgilendirilerek onay alınmıştır. Çalışmada, fetal hareketlerin değerlendirilmesini ve kalıpların tutarlılığını kolaylaştırmak için tüm gebe kadınlar hamileliğin ikinci üç aylık dönemindeki vakalardan seçilmiştir. Veri kümesindeki fetal ultrason değerlendirmeleri, 6C1 HD dönüştürücüye sahip bir Siemens Acuson S3000 kullanılarak gerçekleştirilmiştir. Çalışmada kullanılan ultrason sistemi, 4-4.5 MHz frekanslı dışbükey bir dönüştürücü ve obstetrik bir ultrason ön ayarını içermektedir.

Tez kapsamında veri kümesi oluşturma sürecinin bir parçası olarak, fetal anatomik yapılar ilk olarak ultrason videolarından çıkarılmıştır ve her anatomik yapının sıralı görüntüleri oluşturulmuştur. Fetal anatomik yapıların ultrason taramaları daha sonra anatomik yapılar için gerçek sınıf etiketleri oluşturmak üzere iki etiketlenmiştir. Fetüsün her açıklamalı anatomik yapısının görüntüleri, video çerçevelerinin sıralı sırasına göre 10 kare boyutunda video dizilerine ayrılmıştır. Sonuç olarak, sağlıklı hamilelik sırasında farklı hastalardan toplanan videolar kullanılarak, kafa, gövde, kol, kalp, el, ayak ve bacak dahil olmak üzere fetüsün 7 farklı anatomik yapı hareketi için toplam 587 video çerçeve dizisi oluşturulmuştur. Görüntü dizileri, videodan görüntü alırken herhangi bir çerçeve atlamadan oluşturulmuştur. Çalışma için oluşturulan veri kümesindeki kafa, gövde, el, kol, kalp, bacak ve ayağın anatomik yapıları için fetal hareketleri temsil eden dört rastgele ultrason kareleri Şekil 3.1'de görülmektedir.



Şekil 3.1. Veri setindeki her anatomik yapı için ultrason videolarındaki hareketleri ve değişiklikleri temsil eden kareler (frame)

4. ULTRASON TARAMALARINDAN HAREKET YÖRÜNGE VERİLERİ KULLANILARAK DERİN ÖĞRENME İLE FETÜSTE ANATOMİK YAPILARIN TANINMASI

Fetüste anatomik yapıların ultrason videosunda ortaya çıkan görüntüsü her bir karede hareketli şekilde ortaya çıkmaktadır. Anatomik yapılara ve dokulara ait görüntülerin buldukları konum bilgisi ele alınarak her bir organa ait bir yörünge çıkarılabilir. Fetüs hareketlerinin yörüngelerinin elde edilmesi farklı hareket tiplerinin tanınmasına da imkan verebilir. Temel olarak nesneye ait tek bir konum noktası elde edilerek ağa uygulanabileceği gibi nesneyi temsil edecek şekilde birden fazla nokta da elde edilerek bir derin öğrenme ağına uygulanabilir. Birçok alanda uygulanabilen derin öğrenme algoritmaları, son yıllarda tıbbi verilerin işlenmesinde de yaygın olarak kullanılmaya başlandı. Ayrıca derin öğrenme algoritmaları daha yüksek performans, daha az donanım tüketimi ve daha doğru sonuçlar ile her geçen gün gelişmeye devam etmektedir. Özellikle hareketlerin sınıflandırılması için geliştirilen derin öğrenme modellerinde nesnelere hareket yörüngeleri ile takip edilebilmektedir. Bu durumda hareketli nesnenin her karede değişen konumu hareket hakkında bilgi verebilmektedir.

Tez çalışmasının bu bölümünde, ultrason taramalarından elde edilen hareket yörüngeleri kullanılarak fetüste anatomik yapıların tanınması için yeni bir derin öğrenme mimarisi sunulmuştur. Burada, öncelikle nesne tanıma algoritması kullanılarak video boyunca tespit edilen nesnenin konum bilgileri iki boyutlu düzlemdeki koordinat bilgileri ile kayıt edilmiştir. Daha sonra, fetüse ait anatomik yapıların hareket konumları/yörüngeleri her bir karede tespit edilerek elde edilen noktaların LSTM ağı tarafından sınıflandırılması sağlayan bir uygulama gerçekleştirilmiştir.

Fetal hareketlerin yörünge bilgilerinin anatomik yapılara göre farklı desen örüntüleri oluşturduğu bilinmektedir. Bu nedenle, fetüsteki anatomik yapıların hareket yörüngeleri elde edilerek farklı hareket türlerinin sınıflandırılması sağlanabilir. Bu bölümde, hareket yörüngeleri kullanılarak fetal anatomik yapıların tespiti ve tanınması için YOLOv5 ve LSTM yöntemlerine dayalı bir derin öğrenme yaklaşımı önerilmiştir. Çalışmada öncelikle fetüsteki anatomik yapıların hareketlerini içeren ultrason videolarından bir veri kümesi hazırlanmıştır. Bu veri kümesinde YOLOv5 ağı kullanılarak fetal anatomik yapıların (organların) tanınmasını sağlayan sınıf ve konum bilgileri elde edilmiştir. Bir sonraki adımda ise hareketlerin oluşturduğu 2B yörüngelerin örüntüleri kullanılarak LSTM derin sinir ağları ile fetal hareketin anatomik yapısı belirlenmiştir. Böylece orbital görüntülerden fetal hareketler sınıflandırılmıştır.

4.1. Fetal Hareketler

Fetal vücut hareketlerini izleme kavramı bir yüzyıldan fazla bir süredir mevcuttur. Fetüsün nasıl hareket ettiği ve gebelik sırasında nitelik ve nicelik hareket şekilleri hakkındaki bilgiler çoğunlukla son birkaç on yılda ortaya çıkmıştır. Gerçek zamanlı ultrason, doğal ortamlarında sağlıklı ve bozulmamış fetüslerde kapsamlı motor hareketlerinin kaliteli değerlendirmesine imkan sağlamıştır. Ultrason verilerinin sağladığı imkanlar ile erken doğum riski olan, büyüme sorunu olan, kromozom bozukluğu olan fetüslerde, fetal hareketlerin karakteristik özelliklerinin tanınabilmesini sağlamıştır (Velazquez vd., 2002). Fetal hareketler arasındaki bir ayırım, tüm vücudun kuvvet veya hızına (örneğin zayıf ve güçlü, kısa ve uzun süreli) veya sadece uzuv hareketlerine dayanabilir. Bu hareket özelliklerine göre fetal hareketlerin karakterizasyonu Tablo 4.1’ de görülmektedir (Velazquez vd., 2002).

Tablo 4.1’ de görülen hareket karakteristikleri öncü bir çalışma olsa da gerçek fetüs hareketlerinin karmaşıklığı ve farklı desenleri bu karakterizasyonla sınırlı değildir. Fetal hareketleri karakterize eden bir çalışmada Tablo 4.2’deki sonuçlar açıklanmıştır (Karadavut, 2011: 47).

Tablo 4.1. Farklı fetal hareket tipleri

Anne Algısı	Düşünülen Hareket	Hareket Tipi	Süresi/Kuvveti
Pozisyon Yenileme, Gerinme	Tüm beden	Yuvarlanma, uzama	Aralıksız/Güçlü (3-30saniye)
Tekmeleme, dürtme, irkilme	Gövde, kol ve bacaklar	Basit, izole	Kısa/Güçlü (1-15saniye)
Kıpır kıpır, zayıf tekme	Düşük kol ve bacak	Basit	Kısa/Zayıf (1 saniyeden az)
Hıçkırık	Göğüs kafesi, izole el ve ayak	Yüksek frekanslı	Hızlı / Zayıf (1 saniyeden az)

Kaynak: (S. Liu vd., 2019: 261)

Tablo 4.2. Anlık motor hareketleri özellikleri

Spontan Motor Hareket Tipi	Ortaya çıktığı hafta	Tanımlama
Preterm Spontaneous Human Motion (SMH)	28 haftadan 36-38. haftaya kadar	Gövde hareketlerini ve pelviktilti de kapsayan aşırı değişken hareketler
(Writhing) Kıvranıci SMH	36-38. haftadan 46-52. haftaya kadar	Daha güçlü, kuvvetli ancak daha yavaş, pelvis ve gövdenin daha az katıldığı değişken hareketler
(Fidgety) kıpır kıpır SMH	46-52. haftadan 54-58. Haftaya kadar	Tüm vücutta irregüler, zarif akıcı devamlı küçük hareketler. Baş, gövde ve ekstremiteler benzer boyutta katılırlar

Kaynak: (Karadavut, 2011: 47)

Gelişmekte olan insan sinir sistemi endojeni motor örüntüler ortaya çıkarır. Bu hareketlerin oluşmasını tetikleyici spesifik uyarılara ihtiyaç yoktur. İnsan fetüsü post menstrüel 9-12. haftalarda geniş değişkenlikte özel hareket örüntüleri irkilme, izole ekstremite hareketleri, seğirme, gerinme, esneme ve nefes alma hareketleri gibi hareketler yapar (Karadavut, 2011: 47).

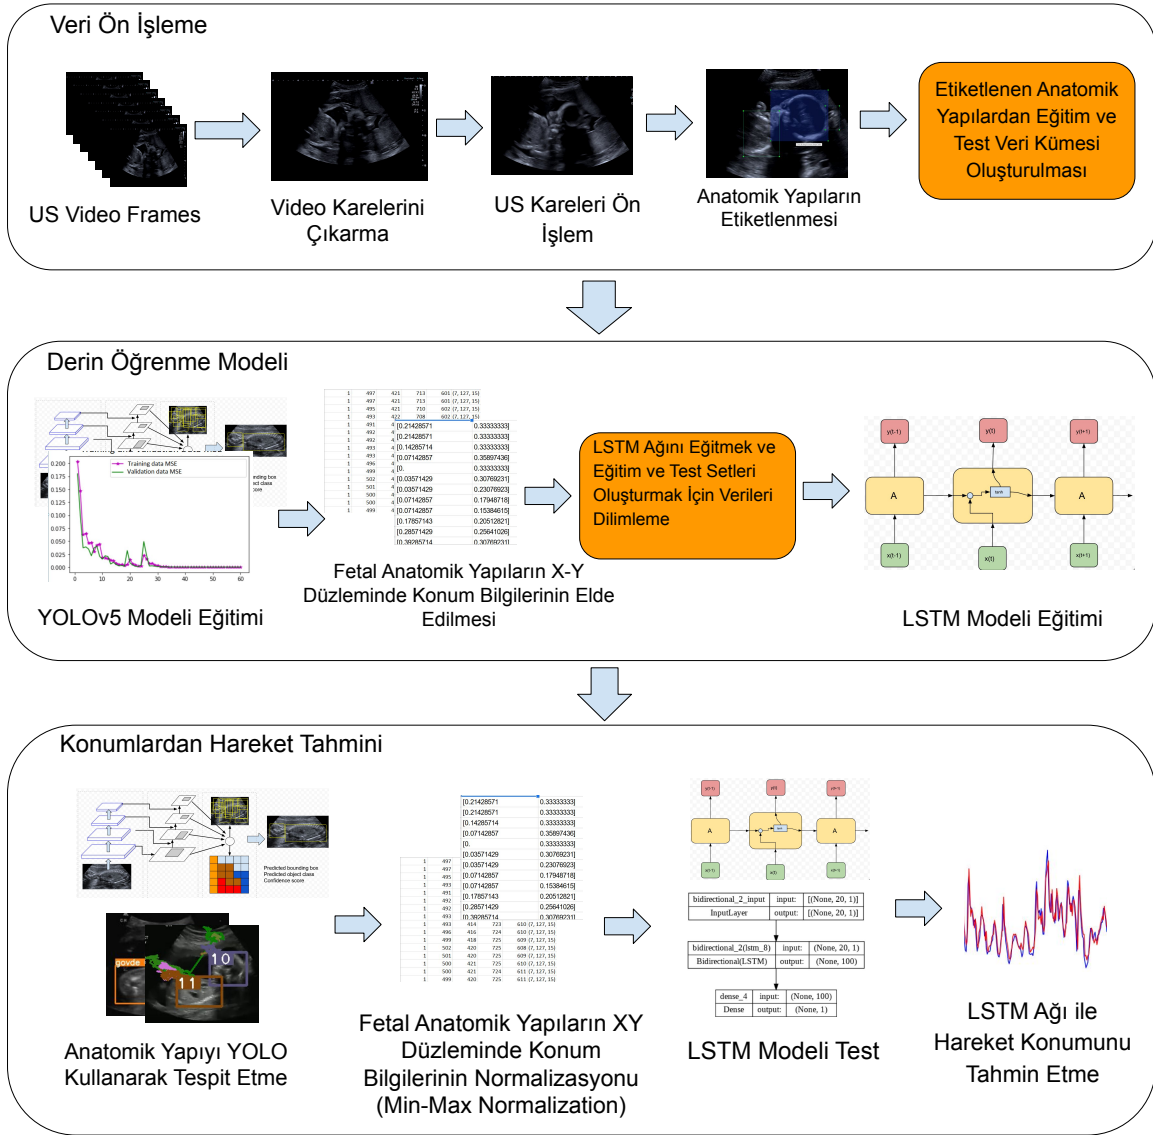
Fetüs 8. haftadan itibaren dış uyaranlara yanıt vermeye başlar. Fetüs sadece bazı tanınabilir dış dürtülere cevap olarak hareket eder. 14. haftadan itibaren fetüs daha genel bir yanıt vermeyi sonlandırır. Bu haftalarda hareketler basmakalıp olmaktan çıkmıştır, artık fetüsün davranışlar sonsuz bir çeşitlilikte, hassas ayırık cevapların bir kombinasyonudur. 25. haftadan itibaren ilk 14 haftada olmayan ve doğum sonrası hayatı için gerekli olan az sayıda refleksler ortaya çıkar (Hooker, 1943).

Fetüs hareketlerini incelemek amacıyla oluşturulan video görüntülerinin süresi ve hangi durumlarda kayıt edildikleri de önemlidir. Dış uyaranlardan bebek hareketleri etkilenebilir. Video kayıtları en az 5 dakika uzunluğunda olmalıdır (Karadavut, 2011: 47). Bebeklerin video kayıt ile değerlendirilmeleri normal hayatta değerlendirmeyi bozabilecek pek çok hatayı önleyebilir. Video kayıtları tekrarlı bir şekilde hareketlerin gözlenmesine imkan verir. Derin öğrenme yöntemleri ile incelenen video kareleri gözlemciye hareketlerin deseni hakkında bilgi verebilir. Farklı hareket desenlerini tanıyabilen bir derin sinir ağı hareketleri sınıflandırabilir. Fetüs hareketlerinin karmaşıklığının ve değişkenliğinin daha kolay anlaşılmasını sağlayabilir. Genel fetüs hareketleri ve dokuların ayrı ayrı hareketlerinin incelenmesi erken doğum riskinin tahmini, fetüs sinir sistemi gelişimi ve fetüs genel sağlığı hakkında bilgi sağlayabilir.

Fetüs hareketlerine yönelik çalışmalar incelendiğinde çoğunlukla genel fetüs hareketleri ele alınmıştır. Fetüs dokularının hareketlerini ayrı ayrı ele alıp değerlendiren kalp hareketleri dışındaki hareketleri inceleyen çalışmaların kısıtlı olduğu görülmüştür.

4.2. Materyal ve Yöntem

Bu çalışmada, ultrason taramalarından elde edilen hareket yörüngeleri kullanılarak fetüste anatomik yapıların tanınması için yeni bir derin öğrenme mimarisi sunulmuştur. Öncelikle ultrason görüntülerindeki organlar YOLO derin öğrenme yöntemi tabanlı bir yöntemle tespit edilerek organların iki boyutlu düzlemdeki noktaları elde edilmektedir. Bir sonraki adımda, elde edilen konum bilgileri bir LSTM ağına uygulanarak organ hareketlerinin iki boyutlu düzlemde tahmin edilmesi sağlanmaktadır. Çalışmada geliştirilen modelin mimarisi **Şekil 4.1**'de sunulmuştur.



Şekil 4.1. Kullanılan derin öğrenme modelinin genel mimarisi

4.2.1. YOLO Algoritması (You Only Look Once)

Nesne tanımda algoritmalar kullanılırken doğruluk ve hız arasında uygun bir denge sağlanması gerekir. Derin öğrenme algoritmaları You Only Look Once (YOLO) ve Single Shot Detector (SSD) gibi tek aşamalı metotlar ve CNN, R-CNN ve hızlı R-CNN gibi iki aşamalı metotlar olarak sınıflandırılabilir. İki aşamalı algoritmalarda sınıflandırma ve konum belirleme işlemleri ayrı ayrı yapılırken tek aşamalı algoritmalarda bir görüntü işlenerek hem konum bilgisi hem de sınıflandırma yapılabilmektedir. İki aşamalı algoritmalar biraz daha yüksek doğruluk oranı yakalasa da genellikle daha yavaştır (Soviany ve Ionescu, 2018: 209). Gerçek zamanlı uygulamalar için hız öne çıkan bir değerlendirme faktörü olduğundan tek aşamalı metotlar gerçek zamanlı uygulamalarda tercih edilir. YOLO tek aşamalı algoritmalar kısmında bulunan bir derin öğrenme algoritmasıdır.

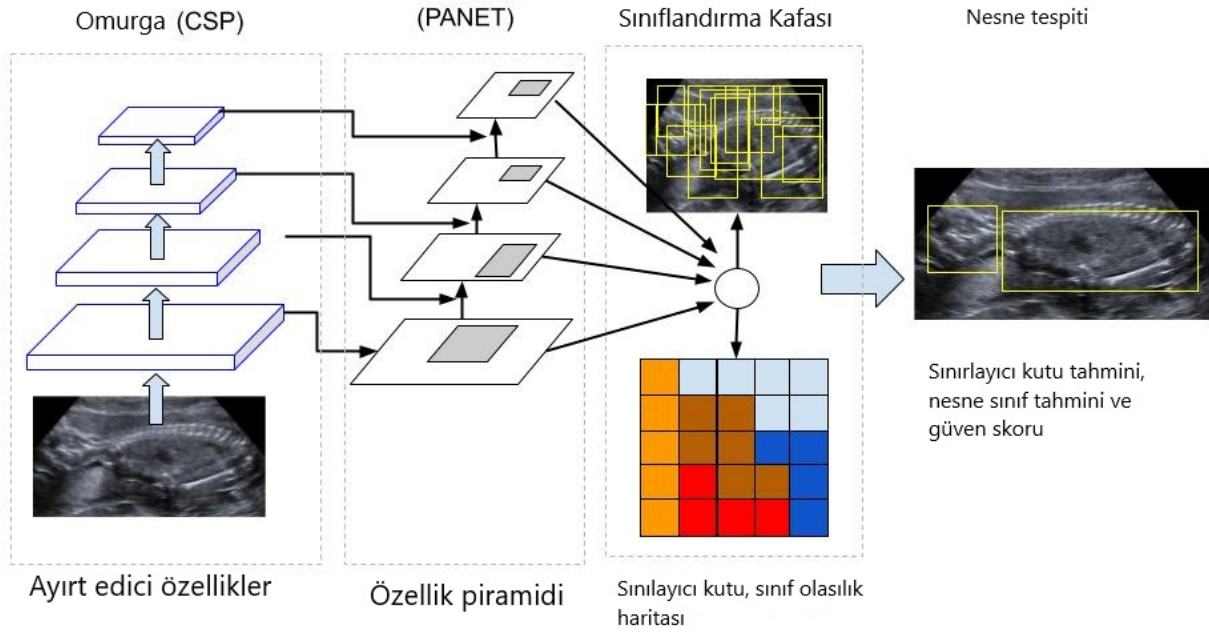
YOLO, Redmon ve arkadaşları (Redmon vd., 2016: 779) tarafından 2016 yılında önerilen ve sınırlayıcı kutu ile nesne tanıma problemlerinde kullanılan bir derin öğrenme yöntemidir. YOLO ile nesnenin hem konum bilgisi hem de sınıflandırması elde edilebilmektedir (K. Chen vd., 2022: 7907). YOLO algoritmasına yakın doğrulukta olan diğer CNN tabanlı algoritmalar, nesne sınıf belirleme ve nesne konum belirleme işlemlerini ayrı ağlarla yaptıkları için daha fazla hesaplama yükü gerektirmektedir. YOLO algoritmasında tüm görüntü ağdan bir kez geçirilir ve oluşturulan sinir ağları, görüntüye birden fazla konumda ve ölçekte ayrı ayrı uygulanır (Turkan vd., 2023: 1).

Tez çalışmasının bu bölümünde, ultrason taramaları üzerinde fetal anatomik yapıların tanınması için YOLOv5 modeli kullanılmıştır. YOLOv5 ağ modeli (Jocher vd., 2022) tarafından 2020 yılında PyTorch tabanlı olarak geliştirilmiştir. YOLOv5 modeli, önceki YOLO sürümlerinden daha yüksek hız sağlayabilir. Ayrıca, YOLOv5 ağı daha küçük boyutlu model dosyaları üretir ve genellikle eğitilmesi daha az zaman alır. Birçok açık kaynak geliştiricisinin desteğiyle oluşturulan YOLOv5, PyTorch tabanlıdır ve nesne tanıma için önceki sürümlerden farklı konfigürasyonlara sahiptir (Malta vd., 2021: 4758; Turkan vd., 2023: 1).

Tipik bir tek aşamalı nesne tanıma yöntemi olan YOLOv5 derin öğrenme modelinin mimarisi Şekil 4.2'de gösterilmektedir. Bu model omurga, boyun ve kafa olmak üzere üç modüler alt bileşenden oluşmaktadır (W. Liu vd., 2021: 042069). YOLOv5'te, giriş görüntüsünden özellikler omurga kullanılarak çıkarılır. Ayrıca YOLOv5 modelinde omurga yapısı olarak DarkNet framewok tabanlı Cross Stage Partial Networks (CSPNet) devreye girmektedir (C.-Y. Wang vd., 2020: 390). YOLOv5'in ikinci modülü olan boyun bileşeninde ise özellik piramidi ağı (FPN) bu bileşen tarafından üretilmektedir. Özellik piramitleri aynı nesneyi farklı boyut ve çözünürlüklerde tanımak için kullanılır ve YOLOv5'te piramit özellikleri elde etmek için genellikle yol birleştirme ağı (PANet) boyun tercih edilir. Son bileşen olan kafada ise YOLOv4'te olduğu gibi nesne tanıma işlemi gerçekleştirilir. Burada nesne sınıflarının olasılıkları ve sınırlayıcı kutular da üretilir (Turkan vd., 2023: 1). YOLOv5 mimari olarak farklı modeller içermektedir ve bu çalışmada fetal anatomik yapıları tanımlamak için en küçük versiyon olan YOLOv5s kullanılmıştır.

YOLO algoritmasında görüntü ızgara olarak bölümlere ayrılır. Her bir ızgara bölmesine karşılık gelen çıktı vektörüyle ağ eğitilir. YOLO algoritmasına yakın doğruluğa sahip CNN temelli diğer algoritmalar nesne sınıfını belirlemeyi ve nesnenin konumunu YOLO belirlemeyi ayrı ayrı ağlarla yaptıkları için daha fazla hesaplama yükü gerektirirler. Oluşturulan sinir ağları birden fazla konum ve ölçekte görüntüye ayrı ayrı uygulanırlar. YOLO algoritmasında ise

görüntünün tamamı bir kez ağdan geçirilir. Ayrıca, YOLO algoritmasının parametreleri değiştirilerek doğruluktan biraz ödün vererek daha hızlı çalışması sağlanabilmektedir. Bu da algoritmayı kullanan araştırmacılar için iyi bir seçenektir. YOLO algoritmasında çıktı olarak sadece sınıf isimleri elde edilmez. Sınıflandırma yapan nesne tanıma algoritmalarında ağır çıktısı tek boyutlu olan ve sınıf sayısı kadar elemanı olan bir vektördür. YOLO algoritmasında ağır çıktısı biraz daha farklıdır. Eğer belirlenen nesnenin konumunu da bulunmak isteniyorsa, bu durumda çıktıda nesnenin konum bilgileri de bulunacaktır.



Şekil 4.2. YOLOv5 derin öğrenme modelinin üç alt bileşenden oluşan mimarisi


4.2.2. Deep-Sort Algoritması

Deep-sort algoritması bir görüntüdeki nesnelerin kimliklendirilmesi amacıyla kullanılan en başarılı algoritmalarından biridir. Algoritma, Kalman filtresi yöntemi kullanarak her bir karedeki nesnelerin bir önceki karedeki hangi nesne olduğunu belirleyebilir. Diğer izleme tekniklerine göre daha hızlı çalışır. Bu özelliği gerçek zamanlı veri çalışmalarında tercih edilmesini sağlar (Bewley vd., 2016: 3464). Video görüntüsündeki nesnelerin kimliklendirilmesi nesne tanıma işleminden daha farklı bir işlemdir. Ekranda hareket eden bir nesnenin bir önceki karedeki hangi nesne olduğuna dair bir kimlik tanımlaması yapılmasını gerektirir. Trafikte araçların sayılması, kalabalık ortamlarda insanların gözlenmesi gibi işlemlerde her bir insanın ayrı bir kimlik ile takip edilmesi gerekir. Deep-sort algoritması bu işlemi gerçekleştiren bir algoritmadır.

Bu çalışma kapsamında fetüse ait anatomik yapıların hareket yörüngeleri çıkarılırken yörünge bilgilerinin ayrı ayrı kayıt edilerek incelenebilmesi için kimliklendirilmeleri gerekir. Bunu sağlamak için Deep-sort algoritması kullanılmıştır. Deep-Sort algoritması ile çalışırken nesnenin tanınması için R-CNN, YOLO gibi bir nesne tanıma algoritmalarından biri kullanılabilir. Bu çalışmada YOLOv5 algoritması kullanılarak nesnelere tespit edilmiş, Deep-sort algoritması ile kimliklendirilmiştir. Böylece, hareket eden nesnenin ekrandaki konumu her bir karede kayıt altına alınmıştır. Yörünge bilgileri, iki boyutlu bir düzlemdeki (x, y) noktası şeklinde kayıt edilmiştir. Ayrıca, yörünge bilgilerine zaman boyutu da eklenerek üç boyutlu bir veri gibi değerlendirilebilir. Tez çalışmasında, uygulamada pek çok çalışmada ultrason video dizileri incelenirken zaman boyutu da hesaba katılarak hareketlerin tanımlanması sağlanmıştır.

4.2.3. Uzun Kısa-Sürelili Bellek (long short-term memory) Derin Sinir Ağları


Tekrarlayan sinir ağları (recurrent neural networks, RNN), genellikle bir sonraki adımı tahmin etmek için kullanılan derin öğrenme ağlarıdır. Bu mimari, sıralı verileri işlemek için özelleştirilmiş sinir ağları ailesidir. Diğer ağlardan farklı olarak hatırlayabilirler ve RNN ağlarında girdiler bir sonraki adımı tahmin etmek için birbirleriyle ilişkilidir (Goodfellow vd., 2016). RNN eğitim aşamasında, girdiler arasındaki tüm ilişkiler hatırlanır ve her sonuç bir sonraki adımı besler (Miao vd., 2015: 167; Staudemeyer ve Morris, 2019). CNN daha çok uzamsal olarak ilişkili verileri kullanırken, RNN derin öğrenme yapıları zaman serileri ve dizi verilerini işlemek için geliştirilmiş modellerdir (Goodfellow vd., 2016) ve uygulamalarda yaygın olarak kullanılmaktadır. RNN zaman serileri ve dizi verileri işlemek için yaygın olarak kullanılan modellerdir. RNN makine çevirisi, ses uygulamaları, yazı tanıma, yazar tanıma, doğal dil uygulamalarında kullanılan bir modeldir (Sherstinsky, 2020: 132306).




Şekil 4.3. Yinelemeli bir sinir ağı hücresinin yapısı

Şekil 4.3'te bir RNN hücresi gösterilmektedir. RNN'nin kendisi bilgiyi kalıcı hale getiren döngüler içerdiğinden, bir ağ segmenti olan A, bir $x(t)$ girişine bakar ve bir $y(t)$ çıkışı üretir. Böylece bir döngü, bilginin ağıın bir adımından diğerine geçmesini sağlar (Staudemeyer ve Morris, 2019).

RNN derin öğrenme modelleri, aynı ağıın birden fazla kopyası olarak düşünülebilir ve her hücre bir sonrakine mesaj iletir (Sherstinsky, 2020: 132306). Burada her katmanda bir aktivasyon fonksiyonu uygulanmaktadır (L. Chen, 2021). Böylece RNN için Şekil 4.4'teki gibi zincir benzeri bir yapı oluşur. Zincir benzeri yapı, RNN'nin diziler ve listelerle yakından ilişkili olduğunu ve bu tür veriler için kullanılacak sinir ağıının doğal mimarisi olduğunu ortaya koymaktadır. Ayrıca Şekil 4.5'te görüldüğü gibi RNN yapısındaki her modül tek bir katman içermektedir.



Şekil 4.4. RNN mimarisinde zincir yapısı



Şekil 4.5. RNN yapısında her bir modülün tek bir katman içermesi

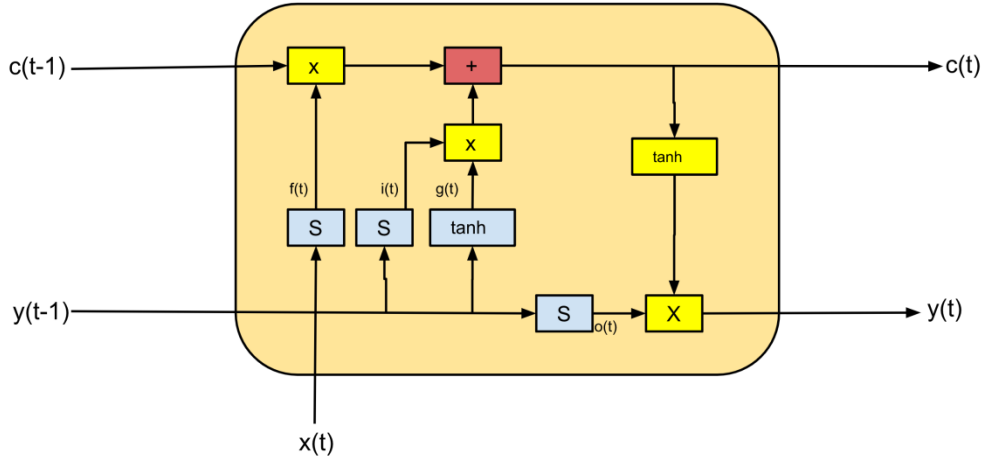
RNN'i başarılı kılan yöntem long short-term (LSTM) ağıdır. Basit RNN modellerindeki gradyan kaybolma problemi LSTM ağları ile çözülmektedir (J. Wang vd., 2016: 2285). LSTM ağları önemli verileri hatırlayıp önemsiz olanları unutarak gradyan kaybolma problemini çözmektedir (Hochreiter ve Schmidhuber, 1997: 1735). LSTM ağında tekrar eden her bir modül içerisinde giriş kapısı, çıkış kapısı, unutma kapısı ve hafıza hücreleri olmak üzere dört katman bulunmaktadır (Park vd., 2020: 20786). Her katman farklı ağırlık değerleri kullanır ve çıkış sigmoid fonksiyonu ve önceki durum kullanılarak hesaplanır (Williams vd., 2002: 709).

Unutma Kapısı (Forget Gate): Bir önceki hücre çıkışı ($y(t-1)$) ve mevcut veri $x(t)$ sigmoid işleminden geçirilerek önceki hafıza hücresi durumu ($c(t-1)$) ile çarpılır. Hücre durum güncellemesi yapılır. Sonucu "1" olan bilgileri hücre durumu olarak (cell state, $c(t)$) taşınmaya devam eder. LSTM mimarisinin çekirdeğini temsil eden $c(t)$ hücre durumu hesaplamasıdır. Hücre durumu sayesinde kaybolan gradyan sorunu azalmış olur.

Giriş Kapısı (Input Gate): Hücre durumu güncellemesi yapılan kapıdır. Önceki ve mevcut bilginin sigmoid işlemine göre güncelleme yapılıp yapılmayacağına karar verilir. 0 olan bilgi önemsiz ve 1 olan bilgi önemli kabul edilir. Tanh aktivasyon fonksiyonu ile veri -1 ve 1 aralığına sıkıştırılır. Sigmoid ve tanh aktivasyon fonksiyonu çıkışları çarpılır ve hangi bilginin güncelleneceği kararına varılır.

Çıkış Kapısı (Output Gate): Bir sonraki hücrenin girişini belirler ($y(t)$). Ayrıca tahmin yapmak için de kullanılır. Bu katmanda önceki bilgi ve mevcut girişin bilgisi sigmoid aktivasyon fonksiyonundan geçirilir. Hücre durumu üzerinde var olan bilgi tanh fonksiyonundan geçirilir. Bu iki sonuç çarpılarak bir sonraki hücre için girişin ($y(t)$) ne olacağına karar verilir. Hücre için işlemler tamamlandığında bir sonraki hücreye gönderilecek olan hücre durumu bilgisi ve $y(t)$ çıkış bilgisi elde edilmiş olur (Park vd., 2020: 20786).

Şekil 4.6'da bir LSTM hücre modülünün yapısı gösterilmektedir. Burada, tanh tanjant aktivasyon fonksiyonu ve S sigmoid aktivasyon fonksiyonudur. Ayrıca X çarpma, + toplama, $y(t)$ çıkış, $c(t-1)$ bir önceki hafıza hücresi durum bilgisi, $c(t)$ bir sonraki hücreye/hücre durumuna giden hafıza durum bilgisi, $y(t-1)$ bir önceki hücrenin çıkışını ve $x(t)$ mevcut veri girişini temsil etmektedir.



Şekil 4.6. LSTM derin öğrenme ağlarında hücre yapısı

RNN ağında sadece tanh aktivasyon katmanı bulunurken LSTM ağında unutmaya kapısı, hücre durum bilgisi, giriş katmanı ve çıkış katmanlarında kullanılan ilave sigmoid aktivasyon katmanları kullanılır (Park vd., 2020: 20786). Eşitlik 4.1 – 4.6’da LSTM mimarisinde çıkışın hesaplanması için için gerekli denklemler sunulmuştur.

S: Sigmoid aktivasyon fonksiyonu

f(t): unutmaya kapısı, i(t): giriş kapısı, g(t): yeni aday değer, c(t): yeni durum değeri, y(t): hücre çıkış değeri

$$f(t) = \sigma(W_{xf}X(t) + W_{yf}y_{t-1} + b^f) \quad (4.1)$$

$$i(t) = \sigma(W_{xi}X(t) + W_{yi}y_{t-1} + b^i) \quad (4.2)$$

$$g(t) = \tanh(W_{xg}X(t) + W_{hg}y_{t-1} + b^g) \quad (4.3)$$

$$c(t) = f(t)c(t-1) + i(t)g(t) \quad (4.4)$$

$$o(t) = \sigma(W_{xo}X(t) + W_{yo}y_{t-1} + b^o) \quad (4.5)$$

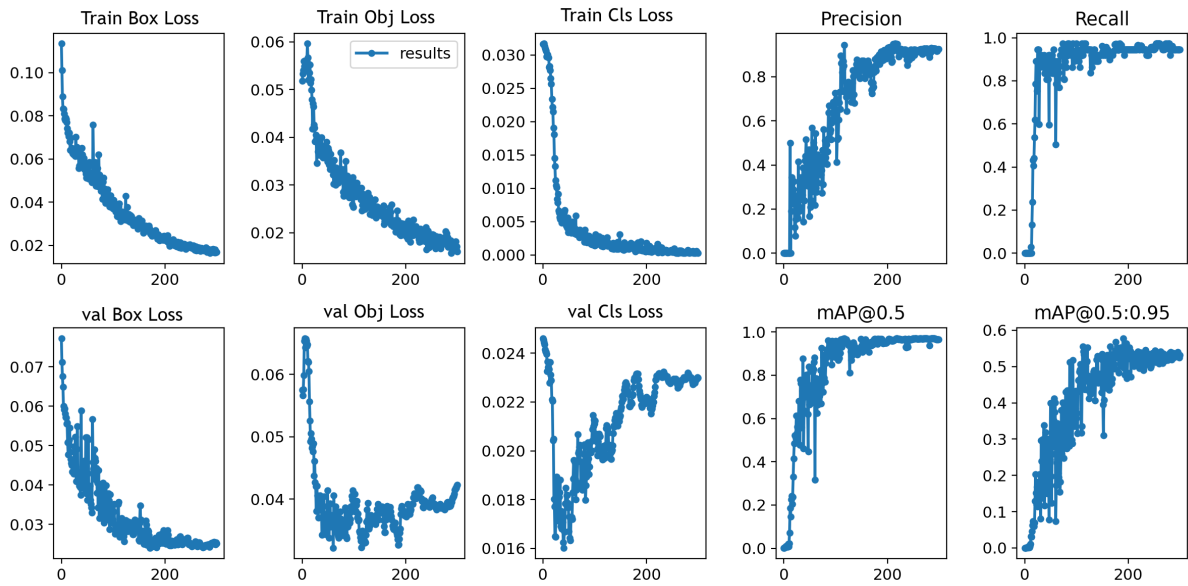
$$y(t) = o(t) \tanh(c(t)) \quad (4.6)$$

4.3. Deneysel Çalışmalar

Bu çalışmada ultrason görüntülerindeki anatomik yapılar derin öğrenme tabanlı hibrit bir yöntem ile tespit edilmiştir. Öncelikle bu çalışma için özel olarak hazırlanan bir fetal ultrason veri kümesinde YOLOv5 kullanılarak anatomik yapıların 2B düzlemdeki konumları elde edilmiştir. Daha sonra elde edilen bu konum bilgisi bir LSTM ağına uygulanarak anatomik

yapıların 2B düzlemdeki hareketleri tahmin edilmiştir. Deneysel analiz kapsamında elde edilen sonuçlar, yörüngeler kullanılarak önerilen hibrit yöntem ile fetüs içerisindeki anatomik yapıların başarılı bir şekilde tespit edildiğini göstermektedir.

Deneysel çalışmalar için ultrason verileri, hazırlanan verisetindeki 10 farklı gönüllüden elde edilmiştir. YOLOv5 kullanılarak fetüsteki anatomik yapının tanınması ve konum bilgisinin elde edilmesi için ultrason taramalarından toplam 2B ultrason görüntüleri (çerçeve) elde edilmiştir. Ultrason videolarından kafa için 500, gövde için 400, kalp için 300 ve kol için 100 olmak üzere 4 sınıfa ait toplam 1300 ultrason taraması etiketlenmiştir. Önerilen YOLOv5 ağının performansı hem hareketsiz (sabit) görüntüler hem de ultrason videoları üzerinde doğrulanmıştır. Doğrulama kümesi için toplam 348 ultrason taraması, dört sınıf için, kafa için 122 ultrason görüntüsü, gövde için 119 ultrason görüntüsü, kalp için 68 ultrason görüntüsü ve kol için 39 ultrason görüntüsü, ağın hareketsiz görüntüler üzerindeki performans ölçümleri için kullanılmıştır. Bu çerçeveler Kütahya Sağlık Bilimleri Üniversitesi Evliya Çelebi Eğitim ve Araştırma Hastanesi'nden uzmanların konsensüsü ile tanımlanmıştır. Ultrason çerçevelerinin uzmanlar tarafından etiketlenmesi için Labellmg (Tzutalin, 2015: 4) yazılım aracı kullanılmıştır.



Şekil 4.7. Ultrason taramalarındaki fetüse ait anatomik yapıların tanınması için YOLOv5s derin öğrenme mimarisinin 100 epok (tur) boyunca eğitimi sonucunda oluşan performansı

Ultrason taramalarındaki fetüse ait anatomik yapıların tanınması için YOLOv5s derin öğrenme mimarisinin 100 epok (tur) boyunca eğitimi sonucunda oluşan performansı Şekil 4.7'de gösterilmiştir. Eğitim aşamasına ait üst satırdaki grafiklerde, kutu (box) koordinatlarına

ilişkin kaybın, nesne varlığına ilişkin güven (objectness) kaybının ve sınıflandırma kaybının zamanla azaldığı görülmektedir. Bu azalmalar, modelin nesnelerin konumlarını, varlıklarını ve sınıflarını giderek daha doğru şekilde tahmin ettiğini göstermektedir. Aynı zamanda precision (kesinlik) ve recall (duyarlılık) gibi performans metriklerinin artması, modelin hem doğru tahmin oranını artırdığını hem de gerçek nesnelere daha yüksek oranda tespit edebildiğini ortaya koymaktadır. Alt satırda yer alan doğrulama metrikleri ise modelin genelleme yeteneğini yansıtmaktadır. Val Box, Val Objectness (obj) ve Val Classification (cls) değerlerinin zamanla dalgalanmasına rağmen genel olarak düşme eğiliminde olması, modelin aşırı öğrenme (overfitting) yapmadığını ve doğrulama verisinde de başarılı sonuçlar verdiğini göstermektedir. Ayrıca, mAP@0.5 ve mAP@0.5:0.95 metriklerinde görülen belirgin artış ve sonrasında sağlanan yüksek düzeydeki sabitlik, modelin hem kolay hem de zor Intersection over Union (IoU) eşiklerinde güçlü bir genel başarıya ulaştığını göstermektedir. Özellikle mAP@0.5 değerinin yüksek seviyelere ulaşması, modelin genel performansının oldukça başarılı olduğunu ortaya koymaktadır. Tüm bu sonuçlar, modelin hem eğitim hem de doğrulama aşamalarında dengeli ve başarılı bir öğrenme gerçekleştirdiğini ve pratikte de yüksek performans göstereceğini işaret etmektedir. Diğer taraftan, YOLOv5s'nin eğitiminde yığın boyutu (batch size) 8, giriş görüntüsü boyutu 640x640 olarak seçilmiştir.

DeneySEL çalışmalarda, fetüsteki anatomik yapıların tanınması için doğrulama seti üzerinde önerilen YOLOv5 ağıının performansı Eşitlik (4.7), Eşitlik (4.8) ve Eşitlik (4.9)'te verilen Hassasiyet / Precision (P), Geri Çağırma / Recall (R) ve F1-skoru (F1) ölçütleri ile ölçülmüştür. P, pozitif olarak tahmin edilen nesnelerin kaç tanesinin gerçekten pozitif olduğunun oranı iken, pozitif olarak tahmin edilen nesnelerin kaç tanesinin gerçekten pozitif olarak tahmin edildiğinin oranı ise R ölçütüdür. Burada, TP=doğru pozitif, FP=yanlış pozitif ve FN=yanlış negatif değerlerini (karmaşıklık matrisinden) göstermektedir.

$$\text{Precision (P)} = \frac{TP}{TP+FP} \quad (4.7)$$

$$\text{Recall (R)} = \frac{TP}{TP+FN} \quad (4.8)$$

$$\text{F1 - score (F1)} = 2 \times \frac{P \times R}{P+R} \quad (4.9)$$

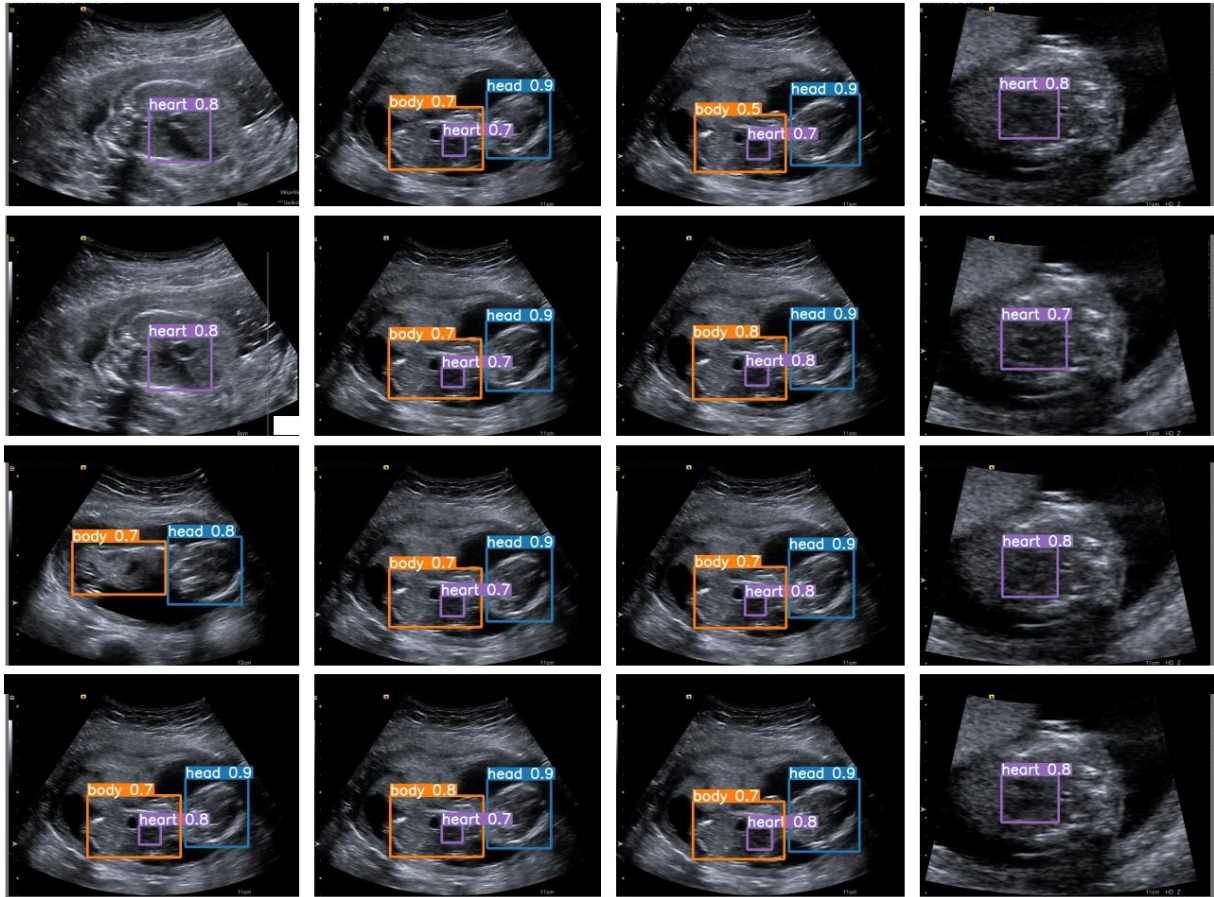
Fetüsteki anatomik yapı ve organların (baş, gövde, kalp ve kol gibi) tanınması için 348 taramadan oluşan doğrulama kümesi ile gerçekleştirilen performans ölçümlerinde elde edilen mAP, P, R ve F1 performans metriklerinin sonuçları Tablo 4.3'te sunulmuştur. Ayrıca bu tabloda her bir düzlem için karışıklık matrisi değerleri TP, FP ve FN değerleri verilmiştir. mAP için 0.50 eşik değerinde, mAP skorları fetal baş, gövde, kalp ve kol anatomik yapıları için

sırasıyla 0.97, 0.91, 0.82 ve 0.89 olarak elde edilmiştir. Benzer şekilde, fetal baş, gövde, kalp ve kol anatomik yapıları için F1 skorları sırasıyla %95,04, %94,42, %88,31 ve %83,23'tür.

Tablo 4.3. Doğrulama seti için YOLOv5 modeli ile elde edilen mAP, P, R ve F1 gibi performans metrik sonuçlarının karşılaştırılması


Anatomic yapı	mAP (@0.50)	P (%)	R (%)	F1 (%)	TP	FP	FN
Kafa	0.97	95.83	94.26	95.04	115	5	7
Gövde	0.91	96.49	92.44	94.42	110	4	9
Kalp	0.82	79.07	100.0	88.31	68	18	0
Kol	0.89	84.21	82.05	83.23	32	6	7

Şekil 4.8'de fetal ultrason veri kümesinde YOLOv5 yöntemi kullanılarak fetüsün baş, gövde ve kalp gibi bazı anatomik yapılarının tanınmasına ilişkin sonuçlar gösterilmektedir. Buradan fetüse ait anatomik yapıların YOLOv5 tabanlı yöntemle başarılı bir şekilde tanındığı, nesnenin sınırlayıcı kutularla etiketlendiği ve puanlarının da belirtildiği görülmektedir.




Şekil 4.8. Fetal ultrason veri kümesinde YOLOv5 yöntemi kullanılarak fetüsün baş, gövde ve kalp gibi bazı anatomik yapılarının tanınması

Bu tez çalışmasında, Deep-sort algoritması kullanılarak ultrason videoları üzerinde nesnelere tanımlanmıştır (Dandıl vd., 2021: 208; Turkan vd., 2023: 1). Ayrıca, YOLOv5 kullanılarak, anatomik yapılar (baş, kalp ve vücut gibi) ultrason taramalarından tanımlanmıştır. Buna ek olarak, hareketleri izlenerek hareket yörüngeleri çıkarılmıştır. Bu bağlamda, Şekil 4.9., fetal ultrasonda tanımlanan anatomik yapıların hareketlerinin ultrason videosu sırasında Deep-sort algoritması ile izlenmesini ve hareket yörüngelerinin çıkarılmasını göstermektedir. Burada, fetal anatomik yapının sınırlayıcı kutusunun sol üst köşesi konum bilgisi için temel olarak kullanılmıştır. Ayrıca, tespit edilen anatomik düzlemlerin yörüngesi oluşturulmuş ve farklı renklerle 2B yörünge desenleri oluşturulmuştur.



Şekil 4.9. Fetüsün anatomik yapılarının hareket yörüngelerinin örüntülerinin çıkarılması

Fetal görüntüler üzerinde anatomik yapıların yörüngeleri çıkarıldıktan sonra anatomik yapıların hareket yörüngeleri csv dosyaları olarak ham veri şeklinde elde edilmiştir. Hareket yörüngeleri ile kalp ve kafa için oluşturulan 2B sinyaller Şekil 4.10'da sunulmuştur. Ayrıca elde edilen yörünge verilerinde ekranın genişliği ve yüksekliğine bağlı olarak farklı değerler görülebilmektedir. Fetüsün anatomik yapısının ekranda bulunduğu yere bağlı olarak x ve y koordinat bilgileri de değişebilmektedir. Bu nedenle yörünge verilerini daha anlamlı hale getirmek için elde edilen sinyaller min-max normalizasyonuna tabi tutulmuştur.



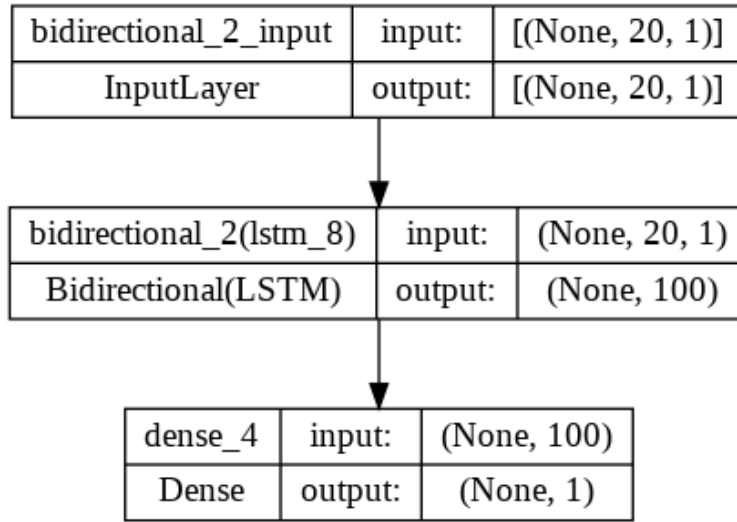
Şekil 4.10. Normalize edilmiş konum noktalarının hareket yörüngeleri için x ve y eksen değerleri (kalp ve kafa).

Fetüsteki anatomik yapıların hareket noktaları ekranda bir çizgi ile birleştirildiğinde farklı desenler ortaya çıkmaktadır. Dolayısıyla fetüsteki anatomik yapıların konum bilgileri Şekil 4.10'da olduğu gibi 2B bir düzlemde x ve y noktalarını gösteren bir grafik olarak görüntülediğinde hareketlerdeki farklılıklar tespit edilebilmektedir. Bu açıdan bakıldığında, referans alınacak anatomik yapıların konum bilgisi belirlenirken algoritma tarafından belirlenen sınırlayıcı kutunun bir köşesi veya sınırlayıcı kutunun orta noktası kullanılabilir. Bazı hareketlerde orta noktanın referans alınması tanımlayıcı bir fark yaratmayabilir ancak kalp atışı hareketi gibi hareketler için nesnenin orta noktası değişmeyecektir. Bu gibi durumlar için nesnenin köşe noktalarını dikkate almak daha uygun olacaktır. Nesnenin tek bir köşesi yerine, sınırlayıcı kutunun tüm köşeleri yörünge verisi olarak elde edilebilir. Bu durumda nesnenin ekranda değişen boyutu gibi ek özellikler de sınıflandırma amacıyla kullanılabilir.

Ultrason görüntüsündeki her bir anatomik yapı için aynı nokta referans alınarak konum bilgisi alındığında sekans şeklinde bir veri kümesi oluşur. Her noktanın x ve y bileşenleri olan bir vektör olarak değerlendirilmesi, sadece bir eksenin değişiminin incelenmesi gibi yöntemler elde edilerek yörünge verileri incelenebilir. Bir veri serisinde bir sonraki veriyi tahmin etmek için kullanılan LSTM yöntemi, sıralı yörünge verilerinin zamana bağlı olarak incelenmesi için uygun bir yöntemdir. Dolayısıyla bu çalışmada 2B sinyal dizilerine dönüştürülen yörünge verileri LSTM ile sınıflandırılmış ve fetüsteki hareketin hangi anatomik yapıdan kaynaklandığı tespit edilmiştir. Bu yörünge bilgisi anatomik yapı türüne göre farklı videolardan mümkün olduğunca toplanmış ve LSTM ağının eğitimi için bir veri kümesi oluşturulmuştur.


LSTM ağı, girdi olarak belirli sayıda elemana sahip dizilerle çalışır. Konum verilerini dizilere bölerken, hareketin farklılıklarını ortaya çıkarmak için ardışık konum bilgisini kullanmak gerekir. LSTM ağına uygulanacak her bir dizinin eleman sayısına göre elde edilen

ardışık konum verilerinin bölünmesi gerekmektedir. Bu nedenle eğitim için LSTM ağına uygun olarak hareketi tanımlamaya yetecek bir nokta dizisi belirlenmiş ve LSTM ağına girdi olarak uygulanmıştır. Burada, 2B sinyal dizisine dönüştürülen yörünge verilerinin sınıflandırılması için kullanılan LSTM ağının yapısı Şekil 4.11'de gösterilmiştir. Eğitim ve test, LSTM ağının çıkışında tam bağlı bir katman kullanılarak yapılır. Bu LSTM ağını eğitmek için hareket noktaları 20 noktadan oluşan dizilere bölünmüştür. Eğitimde kullanılmayan 100 hareket noktası verisi de test işlemlerinde kullanılmıştır. Oluşturulan LSTM ağı 100 epok için eğitilmiştir. Ayrıca fetüsün anatomik yapılarına ait hareket yörünge verileri Intel Core i5 CPU ve Intel UHD Graphics 620 grafik kartı ile donatılmış bir bilgisayarda oluşturulmuştur. Verilerin normalleştirilmesi, LSTM ağının eğitimi ve testi, Google Colab aracılığıyla 2.20GHz Xeon (R) CPU ve NVIDIA Tesla T4 GPU'ya sahip bir bilgisayarda gerçekleştirilmiştir.




Şekil 4.11. 2B sinyal dizisine dönüştürülen yörünge verilerinin sınıflandırılması için kullanılan LSTM ağının yapısı

Şekil 4.12'de, ultrason videolarından elde edilen fetal kalp anatomik yapısının ve fetal hareketlerin dört karesi gösterilmektedir. Frame (Çerçeve) 1, Frame (Çerçeve) 4, Frame (Çerçeve) 12 ve Frame (Çerçeve) 26'da kalbin görsel deseninin ve dolayısıyla hareketlerinin değiştiği görülmektedir. Buradan, kalbin ultrason videolarındaki her bir karedeki hareket yörüngesinin örüntüsü çıkarılarak anatomik yapı sınıflandırılabilir.

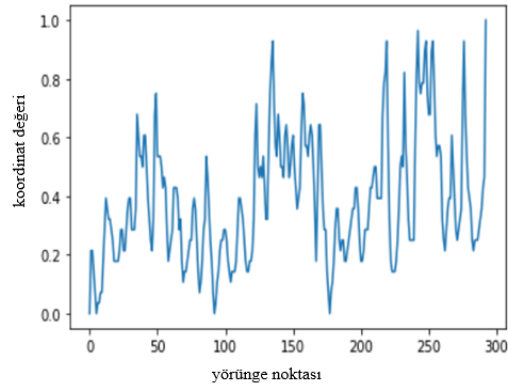


Şekil 4.12. Farklı ultrason çerçevelerinde fetal kalbin anatomik yapısının hareketlerindeki değişiklikler

Şekil 4.13(a)'da görüldüğü gibi, fetüste YOLOv5 tarafından tanınan kalbin hareket verileri normalize edildiğinde, Şekil 4.13(b)'deki gibi x ve y bileşenleri değişen bir grafik elde edilir. Kalp atışları sırasında kalbin boyutu değişir ve bu nedenle sınırlayıcı kutunun konumu da değişebilir. Bu değişim kalp atışı hareketlerinin yakalanmasını sağlayabilir. Sınırlayıcı kutunun orta noktası referans alınarak yapılan deneysel çalışmalarda, kalp atışı hareketi gibi nesnenin boyutunun değiştiği durumlarda hareket farklılıklarını yakalamak mümkün olmayabilir. Sınırlayıcı kutunun dış kenarlarından bir nokta referans alınırsa kalp atışı hareketindeki değişiklikler daha doğru bir şekilde gözlemlenebilir.



(a)

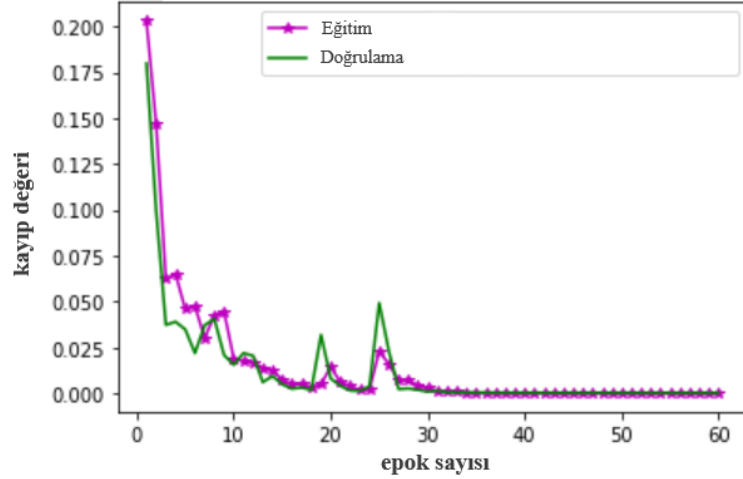


(b)

Şekil 4.13. (a) YOLOv5 kullanılarak fetüsün video görüntüsünden kalbin anatomik yapısının tanınması ve sınırlayıcı kutunun oluşturulması, (b) Kalbin x eksenini için hareket yörüngesi konum verilerinin normalleştirilmesi


Hareket yörüngelerinden üretilen 2B sinyal verilerinden anatomik yapıların tahmini için oluşturulan LSTM ağında yaklaşık 21 bin parametre eğitilmiştir. Bu LSTM ağında ilk katmanda

çift yönlü bir LSTM (Bi-LSTM), 50 hücreden oluşan bir ara katman ve tek çıkışlı bir çıkış katmanı bulunmaktadır. Ara katmanda aktivasyon fonksiyonu olarak ReLu kullanılmış ve çıkış softmax fonksiyonu ile tahmin edilmiştir. Konum verisi 20 elemana bölünerek LSTM ağına uygulanmıştır. LSTM ağ eğitimi kayıp fonksiyonu değişim grafiği Şekil 4.14'te görüldüğü gibidir.

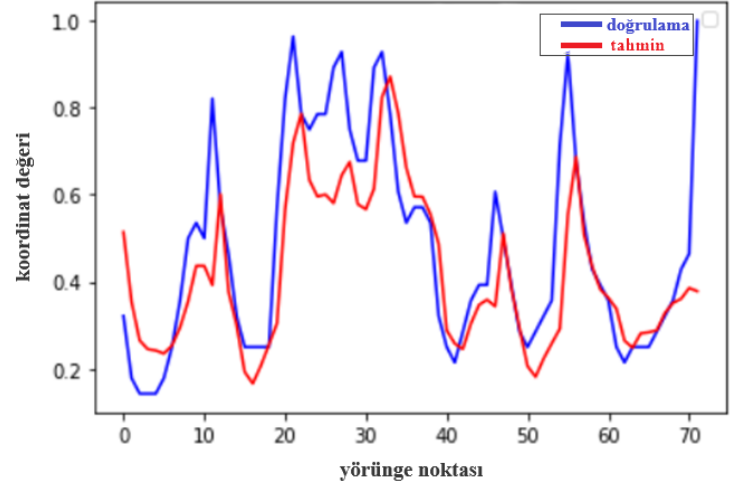


Şekil 4.14. LSTM ağ eğitimi ve doğrulamasında kayıp fonksiyonu değişimi

DeneySEL çalışmalarda, 100 epok ile eğitilen LSTM ağı kullanılarak eğitim ve test verileri üzerinde fetal anatomik hareketler tahmin edilmiştir. Şekil 4.15(a)'da x eksenini boyunca kalp için eğitim ve tahmin değerlerinin karşılaştırılması, Şekil 4.15(b)'de ise eğitime dahil edilmeyen test verileriyle yapılan analizlerde doğrulama ve tahmin sonuçlarının karşılaştırılması gösterilmektedir. Eğitim verileriyle tahmin için ortalama karesel hata (mean square error, MSE) değeri 0.0069 iken, doğrulama verileri için ortalama MSE değeri 0.0097 olarak hesaplanmıştır. Buradan, tahmin sonuçlarının genel olarak gerçek verilerle uyumlu olduğu ve LSTM ağının hem eğitim hem de doğrulama setlerinden kalp hareketlerinin özelliklerini tanıyabildiği görülebilir.



(a)



(b)

Şekil 4.15. (a) Eğitim verileri için önerilen LSTM ağının fetal kalp hareketlerinden anatomik yapı tahmini, (b) doğrulama verileri için önerilen LSTM ağının fetal kalp hareketlerinden anatomik yapı tahmini

5. ULTRASON TARAMALARINDAN FETAL HAREKETLERİN SINIFLANDIRILMASI İÇİN DİKKAT MEKANİZMASI TABANLI YENİ BİR DERİN ÖĞRENME MODELİ GELİŞTİRİLMESİ

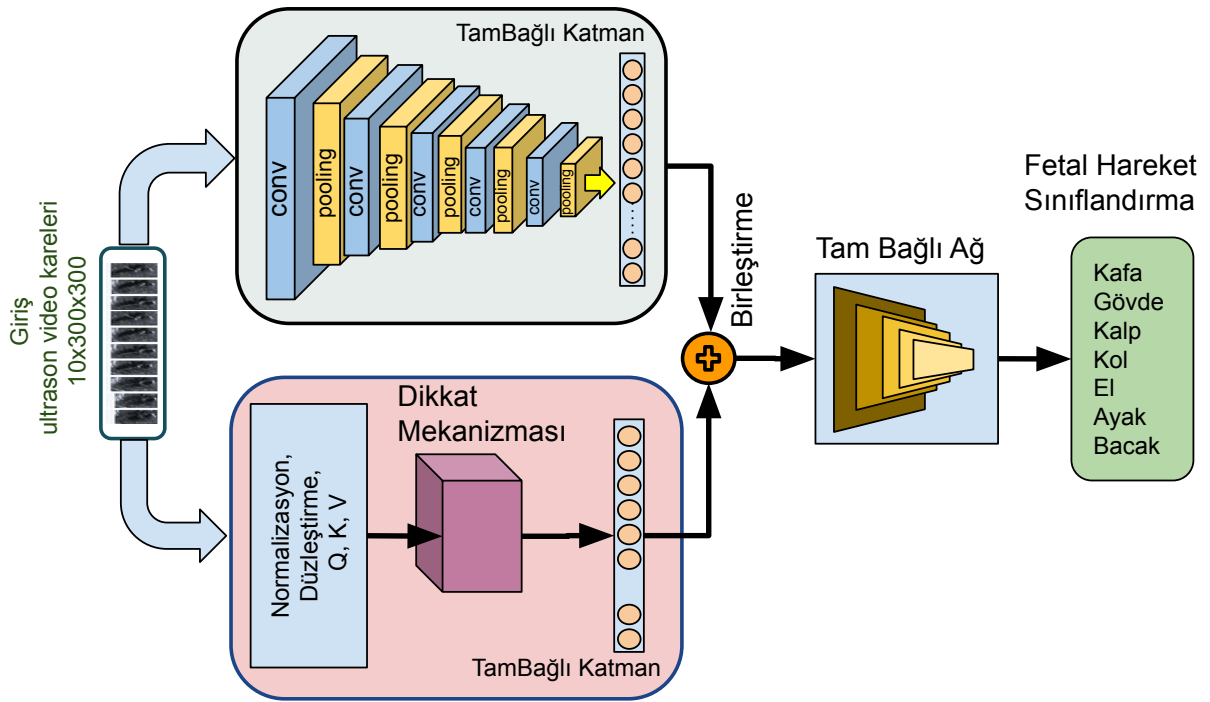
Fetüste iyilik halinin bir ölçüsü de hareketlerdir. Normal fetal hareketler uygun şekilde işleyen bir merkezi sinir sistemini, risk içermeyen sağlık bir fetüsü yansıtır (Turner vd., 2023: 100782). Fetal motor davranışları sağlıklı gelişimin önemli bir göstergesidir. Fetal davranış ve fetal beyin gelişimi arasındaki ilişkilerin anlaşılması konusunda sınırlı bilgi bulunmaktadır. Fetüs anatomik yapı hareketlerinin belirlenmesi, tanınabilmesi ve sınıflandırılabilmesi bu açıdan bakıldığında fetüs gelişiminin izlenmesine ve anormal durumların tespitinde fayda sağlayabilir.

Yapılan literatür incelemelerinde fetüs videoları üzerinden hareketlerin incelenmesi ve sınıflandırılması konusunda çok fazla çalışmayla karşılaşmamıştır. Ultrason tabanlı bazı görevlerde, hareketsiz görüntü karelerinin incelenmesi yerine videoların doğrudan analiz edilmesinin daha başarılı sonuçlar verdiği gösterilmiştir (Ouyang vd., 2020: 252). Tez çalışmasının bu bölümünde, ultrason videolarında ortaya çıkan hareketler incelenerek farklı anatomik yapıların hareketlerinin sınıflandırılması amacıyla CNN ve dikkat (attention) mekanizması tabanlı yeni bir derin öğrenme modeli (FetalMovNet) geliştirilmiştir. Ultrason görüntüleme tekniği tıbbi uygulamalarda en çok kullanılan teşhis ve tedavi yöntemlerinden biridir (Huang vd., 2018). Ultrason görüntü işleme uygulamaları büyük veri setlerinin olmaması, doğal görüntülere göre ultrason görüntülerinin farklı olması sebebiyle çeşitli zorlukları barındırmaktadır. Bu amaçla fetüs anatomik yapılarının her biri için video karesi dizilerinden oluşan yeni bir veriseti de oluşturulmuştur.

5.1. Materyal ve Yöntem

Bu çalışmada, ultrason videolarından fetal anatomik yapıların hareketlerini sınıflandırmak için yeni bir derin öğrenme modeli FetalMovNet geliştirilmiştir. Fetal hareket sınıflandırması sürecinde modele girdi olarak kullanılan çerçevelere dikkat mekanizması uygulanmış ve CNN ile birleştirilerek hareket sınıflandırması gerçekleştirilmiştir. Ayrıca ultrason videolarından 7 farklı fetal anatomik yapının hareketlerini içeren yeni bir veri kümesi oluşturulmuştur. Bu veri kümesindeki video kare dizileri önerilen modele girdi olarak kullanılmış ve model fetal hareketleri sınıflandırmak için kullanılmıştır. Fetal hareket sınıflandırması için önerilen FetalMovNet derin öğrenme ağının mimarisi Şekil 5.1'de gösterilmektedir. FetalMovNet modelinde, giriş olarak alınan video kareleri (örneğin, 100×300×3 boyutunda) iki temel bileşen üzerinden işlenmektedir: görsel özellik çıkarımı ve

dikkat (attention) mekanizması. İlk olarak, giriş verisi bir CNN mimarisi aracılığıyla işlenir. Bu CNN yapısı, ardışık olarak yerleştirilmiş konvolüsyon (conv), havuzlama (pooling) ve aktivasyon katmanları ile görsel özellikleri öğrenir ve son aşamada tam bağlı bir katmanla temsil vektörleri üretir. Aynı video kareleri paralel olarak dikkat mekanizmasına da gönderilir. Bu bileşende, karelerin zaman içindeki ilişkileri dikkate alınarak normalizasyon ve Q (query), K (key), V (value) matrisleri oluşturulur. Bu matrisler yardımıyla önemli zaman anlarına odaklanılır ve dikkat ağırlıkları elde edilir. Bu dikkatli özellikler, tam bağlı katmanlarla işlenerek diğer görsel özelliklerle birleştirilir. Son aşamada, her iki yoldan gelen bilgi (görsel CNN ve zamanla dikkat) birleştirilir ve nihai tam bağlı ağdan geçirilerek sınıflandırma gerçekleştirilir. Model, fetal hareketleri beş farklı kategoriye ayıracak şekilde tasarlanmıştır: kafa (head), gövde (body), kalp (heart), kol (arm), el (hand), bacak (leg) ve ayak (foot). Bu yapı sayesinde FetalMovNet modeli, hem görüntüdeki uzamsal (spatial) özellikleri hem de zamansal (temporal) değişimleri dikkate alarak daha doğru bir hareket sınıflandırması yapabilmektedir.



Şekil 5.1. Fetal hareketlerin sınıflandırılması için önerilen FetalMovNet derin öğrenme ağının mimarisi

Ultrason videolarında ayrıştırıcı özellik çıkarımı, nesne tanıma ve algılama için güçlü bir yaklaşım olarak bilinmektedir. CNN ağları, güçlü özellik temsil kapasitesine sahip oldukça karmaşık ve doğrusal olmayan modellerdir (Gao vd., 2016: 787). Dikkat ve CNN katmanlarının kombinasyonu hareket sınıflandırması için uygun bir model olabilir. CNN, nesnelere ayırt edici özelliklerini belirlemek için kullanılabilir ve dikkat süreci, hareketin her karede ortaya

çıkardığı önemli değişim modellerini ayırt etmek için kullanılabilir. Bir sinir ağında dikkat mekanizmasının kullanılması, görüntünün farklı bölgelerinin ağırlıklandırılmasını sağlar. Ağın arka plan gibi önemsiz özellikler yerine daha önemli özelliklere odaklanmasını sağlar. Dikkat aynı zamanda önemsiz kısımların ağırlığını azaltır ve önemli kısımların ağırlığını artırır. Bu da öğrenme için önemli olan alanlara odaklanmayı mümkün kılar. Dolayısıyla dikkat mekanizması, fetal ultrason video kareleri arasındaki değişikliklerin önemli ve ayırt edici özelliklerini öğrenmek için karelere uygulanabilir.

Geleneksel, daha basit CNN tabanlı mimariler hiyerarşik özellikler çıkarır ancak hareket sınıflandırması için zamansal farkındalıktan yoksundur. Dikkat mekanizmaları, modelin ilgisiz bölgeler yerine ilgili fetal yapılara odaklanmasını sağlayarak özellik seçimini iyileştirir (Turkan vd., 2025). Dikkat mekanizmalarının entegre edilmesi özellik temsilini iyileştirir ve tıbbi görüntüleme sınıflandırma performansını artırır (Kaur vd., 2024). Benzer şekilde, hibrit bir derin öğrenme modeli, karmaşık biyomedikal uygulamalar için geleneksel CNN'lerden daha iyi performans gösterebilir (Singh vd., 2024: 8). Öte yandan, CNN-LSTM modelleri zamansal bağımlılıkları yakalayabilir, ancak daha yüksek hesaplama maliyetlerine sahiptir ve daha uzun eğitim süreleri gerektirir. Sonuç olarak, ultrason uygulamaları için dikkat mekanizmaları, LSTM gibi sıralı bellek modellerinin ek yükü olmadan kritik karelere odaklanarak hesaplama açısından daha verimlidir.

Bu çalışmada, ultrason videolarındaki fetal anatomik yapıların hareketlerini sınıflandırmak için CNN ve dikkatin bir kombinasyonu kullanılarak FetalMovNet adlı yeni bir derin öğrenme modeli geliştirilmiştir. Mimaride, ilk olarak, farklı fetal dokuların bölgeleri ultrason videolarından ardışık çerçevelerde çıkarılmıştır ve her yapının hareketlerinin bir sırasını elde etmek için ardışık 10 çerçeve elde edilmiştir. Ayrıca, önerilen mimaride her bir çerçeve sadece bağımsız bir girdi olarak değerlendirilmemektedir. Ardışık 10 kare birlikte değerlendirilerek hareketin zamana bağlı değişimleri öğrenilir. Çerçeveler arasındaki önemli değişikliklere odaklanmak ve fetal hareketlerin sınıflandırılmasında ayırt edici özellikleri vurgulamak için bir dikkat ağı eklenmiştir. Dikkat ağının girişine uygulanan 10 karenin her biri Flatten katmanı ile düzleştirilir, Query ve Value matrisleri ile çarpılır ve ardından dikkat işlemi uygulanır. Sıralı 10 kareye uygulanan dikkat işlemi, her kare için bir dikkat puanı üretir. Sıralı karelerle birlikte uygulanan Conv işlemi, görüntüdeki ayırt edici hareket örüntülerinin öğrenilmesini sağlar. FetalMovNet modeli daha sonra fetal videolardan açıklanan 7 farklı anatomik yapının hareketlerini sınıflandırmak için kullanılır. Sınıflandırma, CNN'in çıktısı (conv) ile dikkat ağının çıktısının birleştirilmesiyle tamamlanır. Modelde, fetal anatomik

yapıların özelliklerini çıkaran konvolüsyon (conv) katmanı ve dikkat katmanı, ultrason videolarından elde edilen girdi ultrason çerçevelerine uygulanmakta ve bu katmanların çıktıları birleştirilerek tam bağlı bir ağ kullanılarak softmax ile sınıflandırma işlemi gerçekleştirilmektedir.

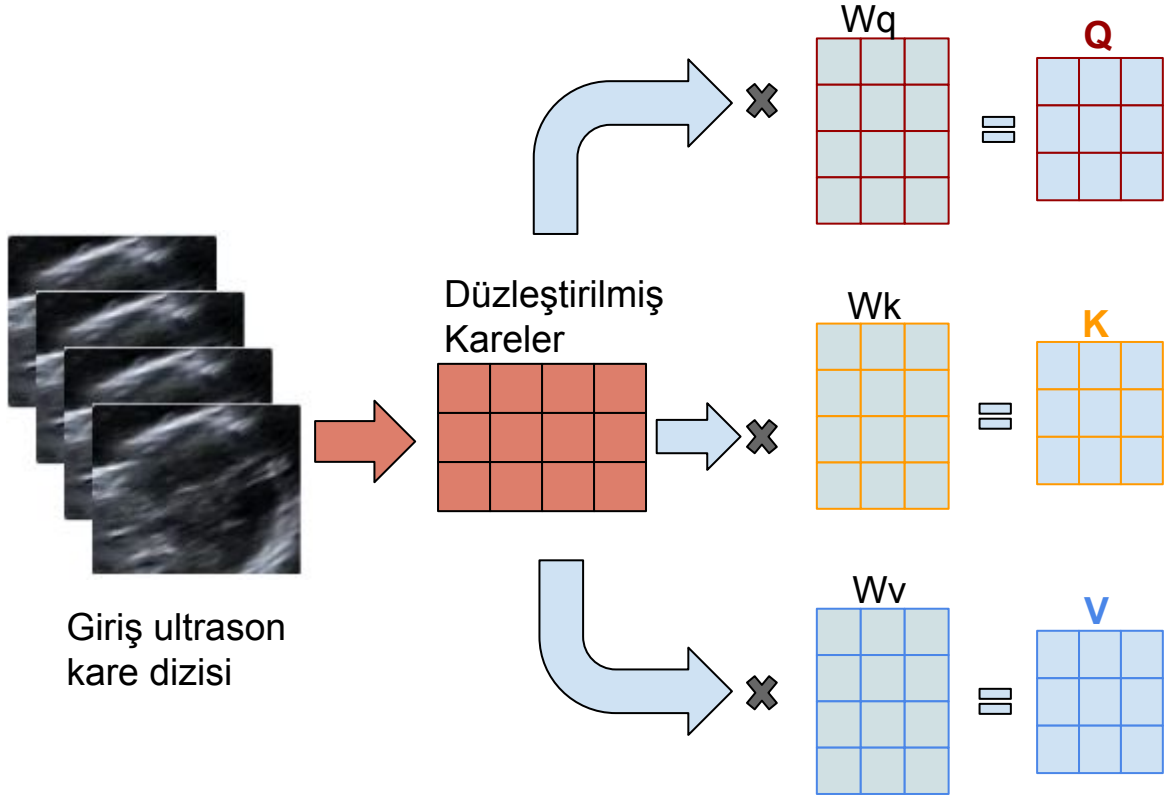
5.1.1. Dikkat Mekanizması (Attention Mechanism)

Bu çalışmada, fetal ultrason video kareleri arasındaki önemli varyasyonları yakalamak için dikkat mekanizması kullanılmıştır. Bu nedenle, fetal hareketi tespit etmek amacıyla, harekete özgü önemli varyasyonları tespit etmek için modelde dikkat ağı kullanılmıştır. Önerilen FetalMovNet mimarisinin dikkat ağı, Şekil 5.1'de gösterildiği gibi bir Flatten (düzleştirme) bloğu, bir Attention (dikkat) bloğu ve bir Tam Bağlı Katman (Fully Connected Layer, FCL)' dan oluşmaktadır. Dikkat ağındaki düzleştirme bloğu, yüksek boyutlu özellik temsillerinden sonraki katmanlar tarafından işlenebilecek bir formata geçişi kolaylaştıran ve böylece modelin daha az önemli bilgilerin etkisini en aza indirirken ilgili özelliklere odaklanma yeteneğini artıran kritik bir adımdır. Ultrasonda fetal hareket sınıflandırması gibi görevler için, bir dikkat bloğunun çıktısının, sınıflandırma görevini yerine getiren ağın son katmanlarına uygulanmadan önce düzleştirilmesi gerekir.

İnsan gözü bir görüntüye baktığında sadece önemli kısımları algılar ve görüntüyü bu şekilde tanımlar. Benzer şekilde insan beyni de gelen bilginin sadece önemli kısımlarına dikkat eder. Dikkat mekanizması insanın bilişsel yöntemine benzer bir şekilde çalışır (Corbetta ve Shulman, 2002: 201). Dikkat mekanizması, derin öğrenme ve büyük veri girdilerini işleyebilmesi ve verilerdeki uzun vadeli bağımlılıkları ve ilişkileri yakalayabilmesi nedeniyle sınıflandırma, görsel tanıma ve metin işleme gibi birçok makine öğrenimi görevinde kullanılmıştır. Özellikle, dikkat mekanizması görüntü sınıflandırmasında görüntüdeki önemli pikselleri vurgulamak ve önemsiz olanları bastırmak için kullanılır. Dikkat mekanizması esas olarak metin çevirisi için geliştirilmiş olsa da görüntü tanıma görevlerinde de yaygın olarak kullanılmaktadır (Azad vd., 2024: 1287).

Dikkat mekanizmasında kullanılan sorgu (Query, Q), anahtar (Key, K) ve değer (Value, V) matrisleri Şekil 5.2'de gösterilmektedir. Burada normalleştirilmiş giriş değeri, modele uygulanan ultrason video karelerinin her birini temsil etmektedir. Fetal anatomisinin hareketini temsil eden 10 giriş karesi, ağırlık değerlerini temsil eden W_q , W_k ve W_v için giriş değerlerini elde etmek üzere Flatten katmanı kullanılarak düzleştirilir. Böylece, W_q , W_k ve W_v ağırlık matrisleriyle çarpılan her girdi, Q, K, V matrislerini elde etmek için tam bağlı katmana uygulanır. Sonuç olarak, ultrason videosundaki her kare için dikkat mekanizması, diğer sıralı

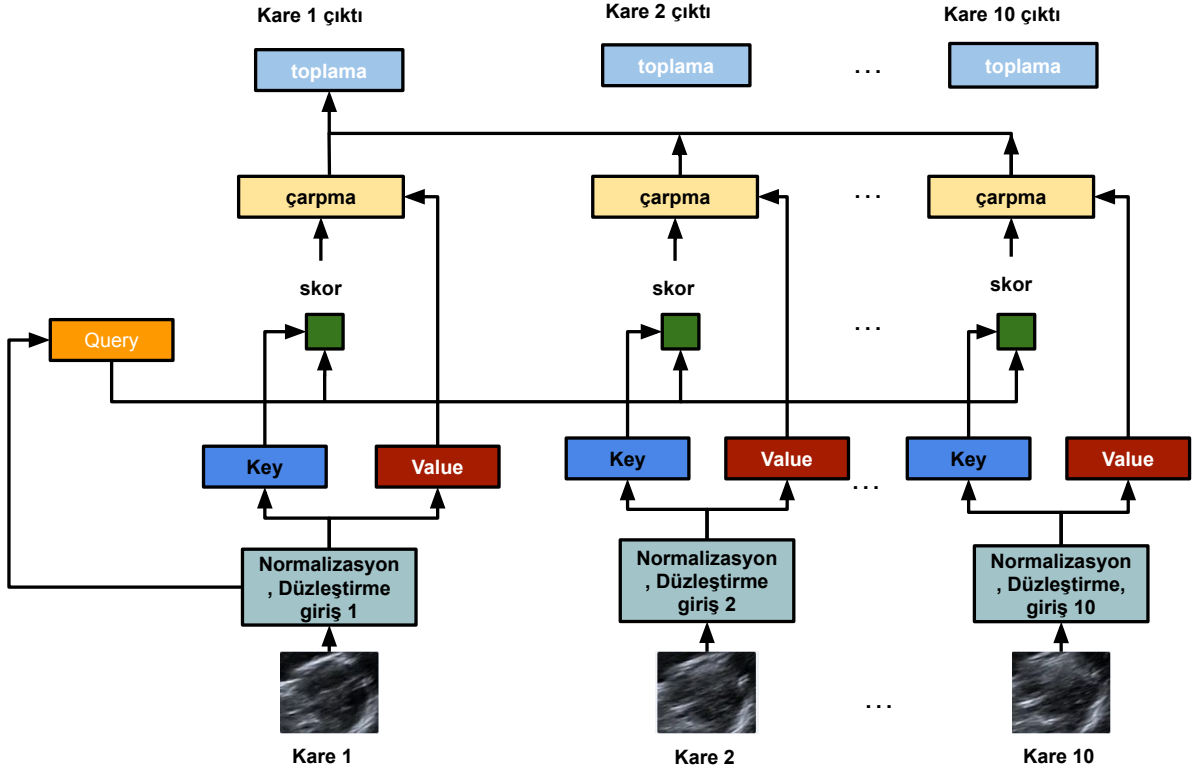
karelere bakılarak işlendiği için tüm fetal hareket değişikliğinin önemli noktalarını yakalar (Turkan vd., 2025).



Şekil 5.2. Dikkat mekanizmasında kullanılan, Q, K, V matrislerinin oluşturulması

Tipik bir Dikkat modülü n girdi alır ve n çıktı üretir. Dikkat mekanizmasında, Şekil 5.3'te gösterildiği gibi, fetal hareketi temsil eden ilk 10 kare giriş ultrason videolarından sırayla seçilir. Ardından, girdilerin hazırlanmasını tamamlamak için her kare Flatten katmanı tarafından normalleştirilir ve düzleştirilir. Bir sonraki adımda, Q, K ve V matrislerini oluşturmak için ağırlıklar hazırlanan girdilerle çarpılır. Bir sonraki adımda, Q ve K matrisleri softmax işlemine tabii tutulur ve her bir girdi ultrason karesi için bir dikkat puanı hesaplanır. Bu puan V matrisi ile çarpılır ve Eşitlik (5.1)'deki z çıktısı elde edilir.

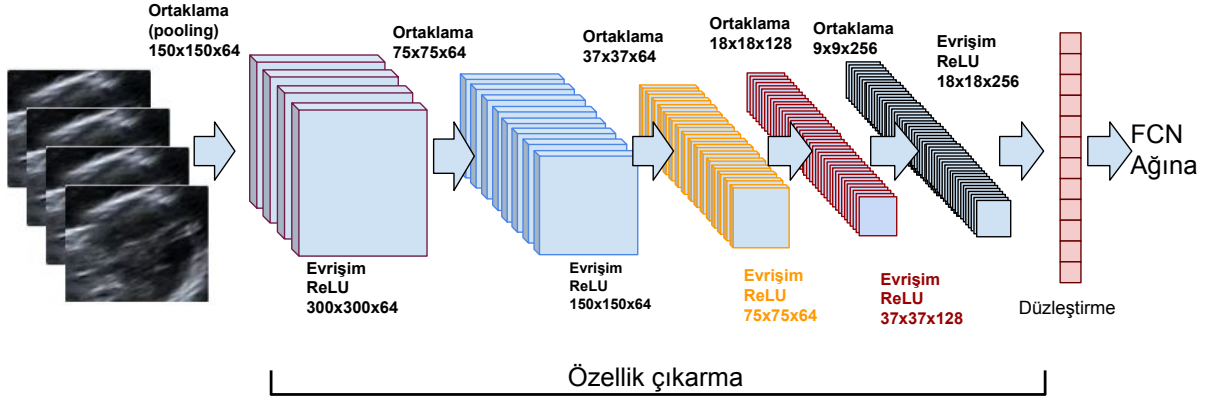
$$\text{softmax}\left(\frac{Q * K}{\sqrt{d_k}}\right) v = z \quad (5.1)$$



Şekil 5.3. Dikkat bloğu iç yapısı ve işleyiş mekanizması

5.2. Evrişimli Ağ (Convolution network)

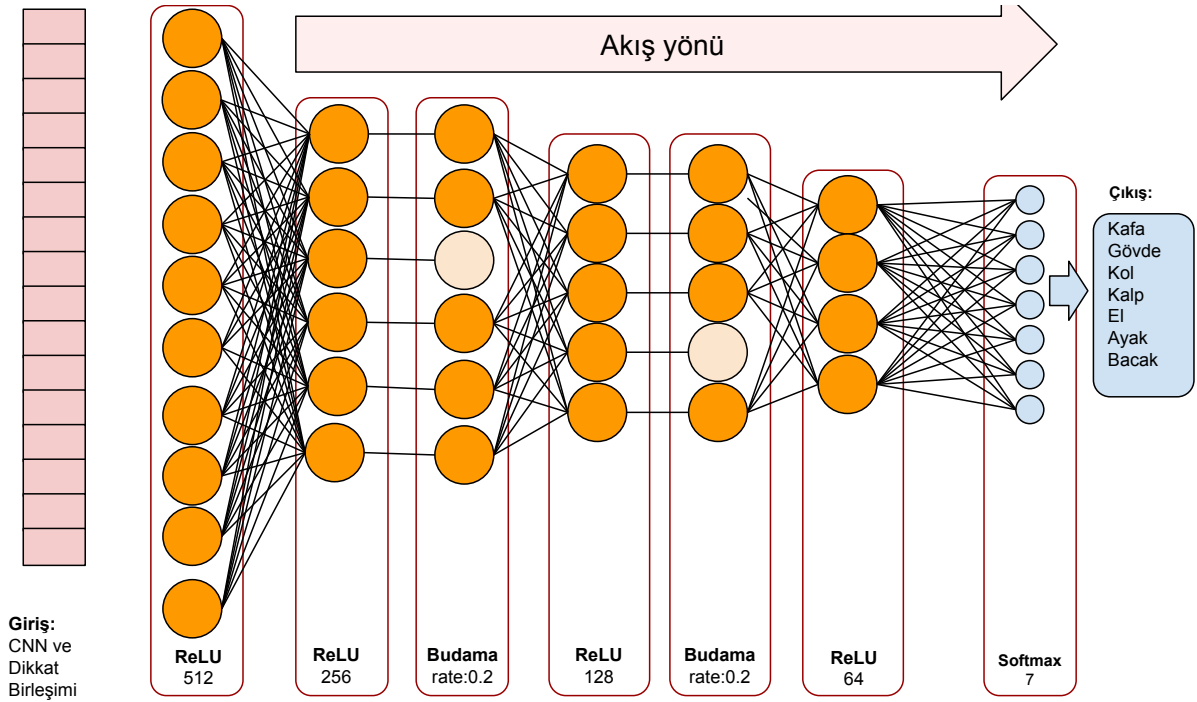
Fetal hareketlerin sınıflandırılması için önerilen FetalMovNet mimarisinin tipik bir CNN modeli olan konvolüsyonel ağ (Conv), Şekil 5.4'te gösterildiği gibi 5 farklı konvolüsyonel ve havuzlama katmanından oluşmaktadır. Bu ağ, 300x300 boyutunda 10 kareden oluşan girdilerle çalışmak üzere tasarlanmıştır. Fetüsün her bir anatomik yapısına ait ultrason video kare dizileri Conv ağına girdi olarak sağlanmaktadır. FetalMovNet mimarisinde, girişe uygulanan her kareye bir dikkat puanı atanır. Bu puanlar tam bağlı katmandan geçirilerek konvolüsyon katmanının çıktısı ile birleştirilir ve ardından softmax sınıflandırıcı ile çıktı elde edilir. Giriş görüntülerinin özelliklerini öğrenen Conv katmanına paralel olarak her bir video karesine uygulanan dikkat işlemi, video kareleri arasındaki bağlantıların öğrenilmesini sağlar. Böylece ağdaki video kareleri için hareket tanımlayıcı özelliklere odaklanılması amaçlanmaktadır. Conv ağında, hesaplama yükünü azaltmak için conv katmanları arasında havuzlama katmanları eklenmiştir. Öte yandan konvolüsyon işleminde 3x3 filtre kullanılmaktadır.



Şekil 5.4. FetalMovNet modelinde kullanılan conv katmanı

5.3. Tam Bağlı Ağ

Şekil 5.5'te gösterilen dikkat ve Conv ağlarının çıkışında, sınıflandırma için kullanılan FCN, 7 farklı sınıf için çıkış üreten bir softmax katmanı üretir. FCN'nin katmanlarında, çıkış haricinde ReLU aktivasyon fonksiyonu uygulanmaktadır. Sınıflandırma aşamasından önce Conv ve dikkat ağlarının çıktıları birleştirilerek 512 boyutunda bir girdi olarak FCN'ye uygulanmakta ve sırasıyla 256, 128, 64 ve 7'ye indirgenmektedir. Ağın ezberlemesini önlemek için 0,2'lik dropout katmanları da eklenmiştir.



Şekil 5.5. Çıkışta kullanılan sınıflandırma katmanı

5.4. Deneysel Çalışmalar ve Bulgular

Önerilen FetalMovNet derin öğrenme modelinin dikkat mekanizması ile fetal hareketleri sınıflandırmadaki performansını değerlendirmek için çeşitli deneysel analizler gerçekleştirilmiştir. Ayrıca, model bileşenlerinin etkisi de bir ablasyon çalışması kullanılarak deneysel çalışmalarda değerlendirilmiştir. Ablasyon çalışmasında CNN ve dikkat yapılarından oluşan FetalMovNet, CNN ve uzun kısa süreli bellek (LSTM) mimarilerinin bir kombinasyonu olan CNN-LSTM [50] ve sınıflandırma için kullanılan tipik CNN mimarileri ile karşılaştırılmıştır. Deneysel çalışmalar, oluşturulan ultrason video veri kümesi üzerinde gerçekleştirilmiş ve modelin performansı temel performans ölçütlerine göre analiz edilmiştir. FetalMovNet mimarisinde, eğitim ve test aşamaları için veri setinin ~%70'i (410) eğitim seti ve kalan ~%30'u (177) test seti olarak kullanılmıştır. Tablo 5.1, fetüsün her bir anatomik yapısı için video eğitim ve test setlerinin sayısını göstermektedir. Çalışmadaki tüm deneysel çalışmalar için Intel Core i5 4.10 GHz CPU, 16GB RAM, NVIDIA RTX A4000 16GB GPU ve 1TB HDD + 500GB SSD disk donanımına sahip bir bilgisayar kullanılmıştır.

Tablo 5.1. Verisetinde eğitim ve test kümelerindeki ultrason tarama/video sayıları

Anatomik yapı	Eğitim kümesindeki video sayısı	Test kümesindeki video sayısı	Toplam
Kafa	86	44	130
Gövde	68	31	99
Kol	57	25	82
Kalp	54	20	74
El	58	16	74
ayak	43	21	64
Bacak	44	20	64
Toplam	410	177	587

Ön-işleme aşamasında, ultrason videolarından/taramalarından elde edilen kareler görüntü etiketlenerek test ve eğitim kümeleri oluşturulmuştur. Görüntüler 300x300 boyutunda olacak şekilde yeniden düzenlenmişlerdir. Daha küçük boyutlu olan görüntülere boşluk (padding) eklenmiş, büyük boyutlu olanlar yeniden uygun şekilde boyutlandırılmıştır. Ultrason görüntüleri siyah beyaz görüntüler olduğundan görüntüler gri ölçekli olarak kullanılmıştır. Ultrason videolarından farklı fetüs dokularına ait bölgeler sıralı karelerden elde edilerek yaklaşık peş peşe gelen 10 kare kayıt edilerek her bir dokuya ait hareketin bir dizisi elde edilmiştir. Böylece her bir dokuya özel video hareketlerini gösteren sıralı kareler elde edilmiştir. Videodan kareler elde edilirken hiç ara vermeden tüm kareler sırayla ele alınmıştır. Kareler örneklenirken herhangi bir kare atlanmadan kare dizileri oluşturulmuştur. Her bir dokuya ait

görüntü dizileri ayrı ayrı klasörleştirilmiştir. Bu görüntüler kullanılarak oluşturulan derin öğrenme modeli eğitilmiştir. Ayrıca, görüntü kareleri normalizasyon işlemine tabi tutularak ağa uygulanmıştır.

En iyi performansı ve genelleştirilebilirliği sağlamak için FetalMovNet, hiperparametre ayarı, optimize edici seçimi, yığın boyutu hususları, aktivasyon fonksiyonları ve eğitim dönemlerini içeren iyi tanımlanmış bir strateji kullanılarak eğitilmiştir. Önerilen FetalMovNet derin öğrenme ağı, Tablo 5.2'de verilen parametrelerle 50 epok için eğitilmiştir. Model eğitimi, Python programlama dili kullanılarak Keras ortamında gerçekleştirilmiştir. Eğitim sırasında erken durdurma yöntemi kullanılarak aşırı uyumun önüne geçilmiş ve modelin en iyi performans gösterdiği iterasyonlarda eğitim durdurulmuştur. Toplu iş boyutu, eğitim verimliliği, model performansı ve bellek kullanımında önemli bir rol oynamaktadır. FetalMovNet ağını eğitirken, batch size (yığın boyutu) 4 olarak ayarlanmıştır. Bu, modelin aşırı uyum sağlamasını önleyen gradyan tahminine daha fazla gürültü ekleyerek daha yumuşak bir yakınsama ve gelişmiş genelleme sağlayabilir. Ayrıca, ağı eğitiminde optimize edici olarak kök ortalama kare yayılımı (RMSprop) kullanılmıştır. RMSprop, her ağırlık için öğrenme oranını, o ağırlığa ait gradyanların son büyüklüklerinin ortalamasına göre ayarlar. CNN'ler genellikle çok sayıda katmana ve parametreye sahip olduğundan, RMSprop'un öğrenme oranlarını ayarlama yeteneği, kaybolan veya patlayan gradyan sorunlarından kaçınmaya yardımcı olur. MSprop, uyarlanabilir öğrenme hızı ayarlamaları gerçekleştirdiği ve ultrason videoları gibi gürültülü veri kümeleriyle iyi çalıştığı için seçilmiştir. Kategorik çapraz entropi genellikle sınıflandırma problemleri için bir kayıp fonksiyonu olarak kullanılır ve model tarafından üretilen her sınıf için gerçek sınıf ile tahmin edilen sınıf arasındaki farkı ölçer. Kategorik çapraz entropi çok sınıflı sınıflandırma için de uygundur. ReLU aktivasyon fonksiyonu, FCN bloğunda kullanıldığında kaybolan gradyan problemini önler ve yakınsamayı hızlandırır.

Tablo 5.2. FetalMovNet mimarisinde kullanılan temel hiperparametreler ve değerleri

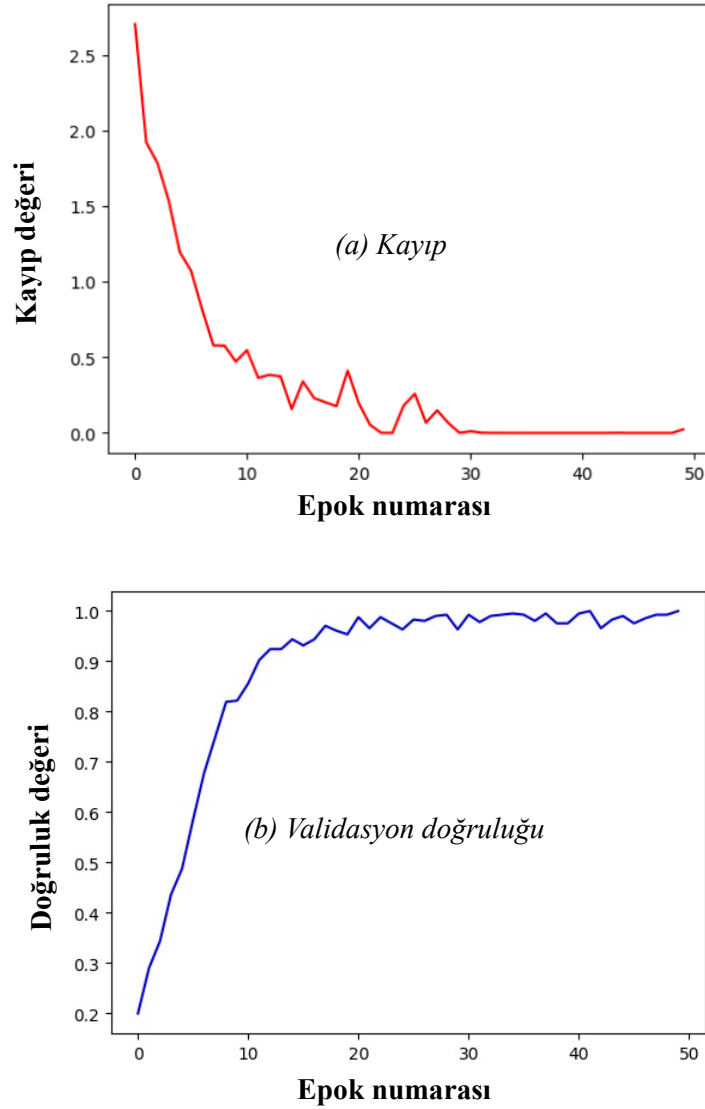
Parametre	Değer
Yığın boyutu	4
Optimizasyon yöntemi	RMSprop
Kayıp fonksiyonu	Categorical cross entropy
Epok sayısı	50
Aktivasyon fonksiyonu	ReLU

Bu çalışmada, ultrason video karelerinden fetal hareketlerin sınıflandırılmasını sağlayan FetalMovNet derin öğrenme ağının mimarisindeki katman yapısı Tablo 5.3'te detaylandırılmıştır. Modelde, her bir girdi video karesi, sekanstaki diğer karelerle birlikte dikkat işlemine tabi tutulmakta ve bir skor üretilmektedir. Bu puanlar tam bağlantılı katmanlardan geçirilir ve konvolüsyon katmanlarının sonucuyla birleştirilir. Softmax fonksiyonu daha sonra fetal hareket sınıflandırmasını tamamlamak için kullanılır. Şekil 5.6'daki kayıp ve doğruluk ilerleme grafikleri değerlendirildiğinde, önerilen FetalMovNet ağının 50 epok boyunca eğitildiğinde üretilen sıralı ultrason görüntü verileri üzerinde genelleştirilmiş öğrenme gerçekleştirebildiği görülebilir. Bu çalışmada önerilen FetalMovNet mimarisinin eğitim süresi değerlendirildiğinde, yaklaşık 30 epok sonrasında doğrulama doğruluğunun stabil hale geldiği gözlemlenmektedir. Benzer şekilde eğitim kaybının da 30 epok sonunda çok fazla değişmediği gözlemlenmektedir. Böylece, önerilen CNN ve dikkat tabanlı FetalMovNet mimarisinin, oluşturulan veri kümesi üzerinde ultrason videolarından fetal hareket tespitinde yüksek bir performansa sahip olduğu sonucuna varılabilir.


Tablo 5.3. Önerilen FetalMovNet mimarisinde katman yapısı ve detayları

Katman tipi	Çıkış biçimi	Bağlı olduğu katman
Input layer	(n,10,300,300)	
Reshape	(n,300,300,10)	Input layer
Conv1	(n,300,300,64)	Reshape
Pooling1	(n,150,150,64)	Conv1
Conv2	(n,150,150,128)	Pooling1
Pooling2	(n,75,75,128)	Conv2
Conv3	(n,75,75,256)	Pooling2
Pooling3	(n, 37,37,256)	Conv4
Conv4	(n, 37,37,512)	Pooling3
Pooling4	(n, 18,18,512)	Conv4
Batch Norm1	(n, 9,9,256)	Pooling4
Flatten1	(n, 20736)	BatchNorm1
Dense1	(n, 256)	Flatten1
Reshape2	(n, 10,90000)	Input Layer
Dense(Q)	(n, 10,1024)	Reshape2
Dense(V)	(n, 10,1024)	Reshape2
Dikkat Layer	(n, 10,1024)	Dense(Q), Dense(V)
Flatten2	(n, 10240)	Dikkat Layer
Dense2	(n, 256)	Flatten2
BatchNorm2	(n, 256)	Dense2
Concatenate	(n, 512)	Flatten1, BatchNorm2
Dense3	(n,256)	Concatenate
DropOut1	(n,256)	Dense3
Dense4	(n,128)	Dropout1
Dropout2	(n,128)	Dense4
Dense5	(n,64)	Dropout2
Softmax	(n,7)	Dense5

Önerilen dikkat derin öğrenme modeli FetalMovNet'in fetal hareketleri sınıflandırmadaki performansını değerlendirmek için mimarinin farklı katmanlarının çıktıları dikkate alınabilir. Şekil 5.7, FetalMovNet mimarisinin Conv4 katmanının çıkışında elde edilen bazı filtreleri göstermektedir. Bu filtreler ağı eğitimi ve sınıflandırma sonuçları hakkında ilk fikri verebilir. Mimarinin Conv4 katmanından elde edilen filtreler, ağı derinliğine bağlı olarak daha soyut, üst düzey özellikler çıkarmaktadır. Özellikle Conv4 gibi daha derin katmanlarda filtrelerin sunduğu özellikler, modelin dikkat mekanizması nedeniyle girdi verisindeki nesne parçalarını, doku detaylarını, şekilleri veya benzersiz yapısal özellikleri öne çıkarmaktadır. Dolayısıyla, bu filtrelerin çıktısı, modelin girdi verilerinde göze çarpan ve kritik bölgeleri belirlemek için kullandığı dikkat odağını da içerebilir.



Şekil 5.6. Önerilen FetalMovNet mimarisinin eğitimi sırasında 50 epok için (a) kayıp ve (b) validasyon doğruluğu değerlerinin değişimi.



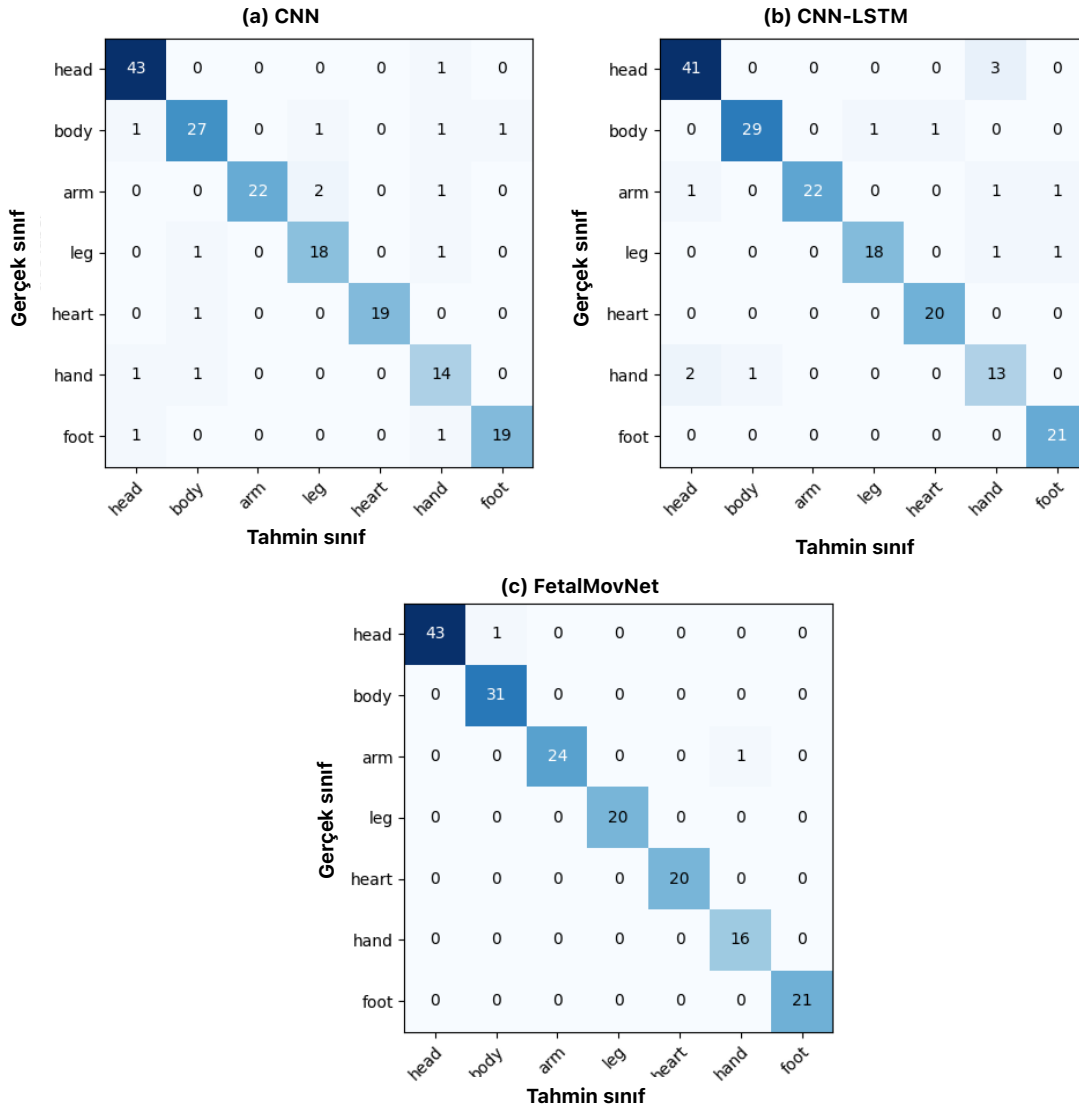
Şekil 5.7. FetalMovNet mimarisinin Conv4 katmanının çıkışında öğrenilen filtre kalıpları

Deneyisel çalışmalarda, fetal anatomik yapıların sınıflandırılmasında önerilen FetalMovNet mimarisinin ve diğer son teknoloji modellerin performansını değerlendirmek için Accuracy (Doğruluk), Precision (P), Recall (R) ve F1-score (F1) temel metrikleri kullanılmıştır. Bu metrikler, karışıklık matrisinden elde edilen gerçek pozitif (TP), gerçek negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) kullanılarak hesaplanmıştır. Eşitlik (5.1)'deki Doğruluk, önerilen modelin tüm sınıflandırmalarda doğru tahmin oranını temsil etmektedir. Diğer metrikler P, R ve F1 bir önceki bölümde anlatılmıştı. Bu çalışma çok sınıflı bir sınıflandırma problemi olduğu için Precision, Recall ve F1-score temel metriklerinin hesaplanmasında makro-ortalama kullanılarak metriklerin ortalama değerleri dikkate alınmıştır. Makro-ortalama yaklaşımında, bir metrik tüm sınıflar için hesaplanırken, bu metriğin sınıf bazında hesaplanan değerlerinin ortalaması dikkate alınmıştır (Turkan vd., 2025).

$$Accuracy (Doğruluk) = \frac{TP+TN}{TP+TN+FP+FN} \quad (5.1)$$

Bu çalışmada önerilen FetalMovNet modeli için, farklı katmanların performans sonuçları üzerindeki etkisini değerlendirmek amacıyla deneysel çalışmaların bir parçası olarak ablasyon işlemi gerçekleştirilmiştir. Ablasyon işlemi, derin öğrenme modellerinin sağlamlığını değerlendirmek ve hangi modülün nasıl çalıştığını gösterdiğini anlamak için kullanılmaktadır. İlk olarak, ablasyon için önerilen FetalMovNet mimarisinde, dikkat katmanı kaldırılarak ve sadece Conv ve FCN katmanları kullanılarak tipik bir CNN modeli oluşturulmuştur. İkinci olarak, tipik bir CNN mimarisi LSTM modeli ile birleştirilerek ablasyon değerlendirmesi için

son teknoloji ürünü başka bir mimari geliştirilmiştir. Daha sonra FetalMovNet, tipik CNN ve CNN-LSTM mimarileri ile elde edilen sonuçların performansı karşılaştırılmıştır. Fetüsün kafa, gövde, kol, kalp, bacak, ayak ve el gibi anatomik yapılarının sınıflandırılmasında elde edilen sonuçları gösteren karışıklık matrisleri Şekil 5.8'de gösterilmiştir.



Şekil 5.8. Fetüsün anatomik yapılarının hareketlerinin sınıflandırılması için testte modeller kullanılarak elde edilen karışıklık matrisi sonuçları. (a) tipik bir CNN mimarisi, (b) CNN-LSTM mimarisi ve (c) önerilen FetalMovNet mimarisi

Şekil 5.8(a) sadece bir CNN ağı ile elde edilen sonuçları gösterirken, Şekil 5.8 (b) CNN-LSTM modeli ile elde edilen sınıflandırma sonuçlarının karışıklık matrisi değerlerini göstermektedir. Öte yandan, Şekil 5.8 (c) önerilen FetalMovNet mimarisi kullanılarak elde edilen sonuçlara ait karışıklık matrisini göstermektedir. Tipik bir CNN mimarisi ile kafa için 1, gövde için 4, kol için 3, bacak için 2, el için 2, kalp için 1 ve ayak için 2 ultrason videosu yanlış sınıflandırılmıştır. Sonuç olarak, CNN mimarisi test setindeki fetal anatomik yapıların

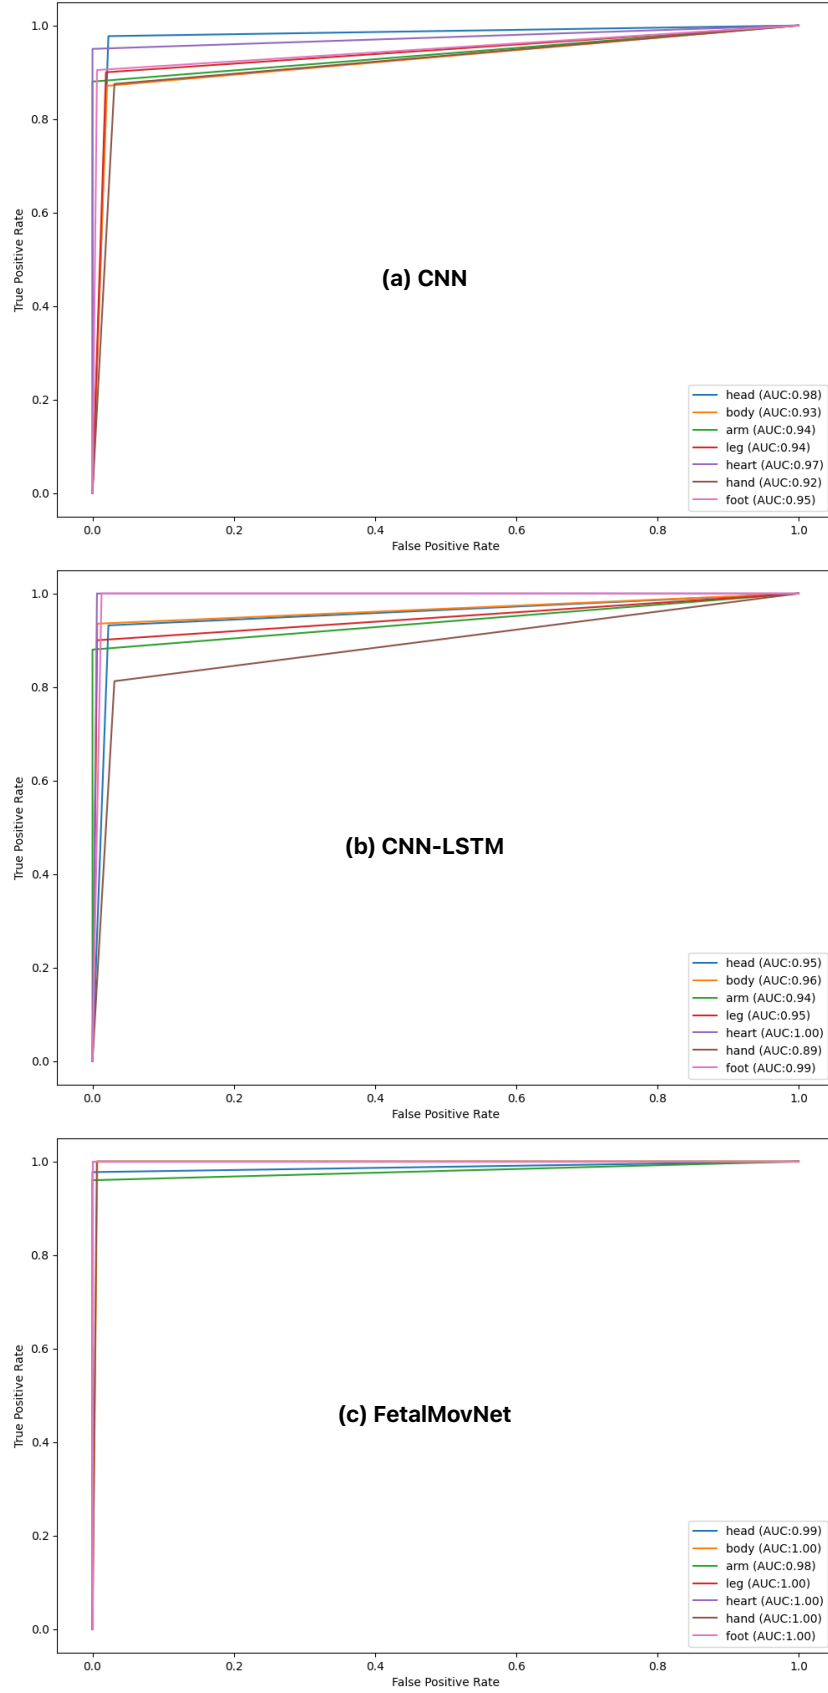
hareketlerini içeren 177 ultrason videosunun 15'ini yanlış sınıflandırmıştır. Buna ek olarak, CNN-LSTM kullanılarak test setindeki toplam 177 ultrason dizisinden 13'ü yanlış sınıfa tahmin edilmiştir. CNN-LSTM mimarisi, test setindeki ultrason dizilerinde kafa için 3, gövde için 2, kol için 3, bacak için 2 ve el için 3 yanlış sınıflandırma yapmıştır. Öte yandan, fetal hareketlerin sınıflandırılması için önerilen dikkat tabanlı FetalMovNet mimarisi kullanılarak test setindeki 177 ultrason videosundan yalnızca 2'si yanlış sınıflandırılmıştır. Baş sınıfındaki 1 hareket videosu vücut sınıfında, kol sınıfındaki 1 hareket videosu ise el sınıfında tahmin edilmiştir. Bu üç karışıklık matrisi birlikte değerlendirildiğinde, önerilen FetalMovNet mimarisinin fetal hareketleri içeren 10 ardışık kareden oluşan ultrason videolarını sınıflandırmada tipik CNN ve CNN-LSTM mimarilerinden daha başarılı olduğu görülebilir.

Tablo 5.4, tipik CNN ve önerilen FetalMovNet mimarilerinin temel metriklerle karışıklık matrislerini kullanarak test seti için performans sonuçlarını göstermektedir. Tipik CNN ve CNN-LSTM mimarileri fetal hareketleri sınıflandırmada anatomik yapılar için sırasıyla 0,9153 ve 0,9265 ortalama doğruluk elde ederken, önerilen FetalMovNet mimarisi 0,9887 doğruluk elde etmiştir. Öte yandan, hassasiyet, geri çağırma ve F1-skoru gibi temel metrikler için önerilen FetalMovNet mimarisi kullanılarak 0,9871, 0,9910 ve 0,9891 puanlar elde edilmiştir. Bu sonuçlar, önerilen FetalMovNet mimarisinin fetal anatomik yapıların hareketlerini tespit etme ve sınıflandırma konusunda CNN ve CNN-LSTM mimarilerine kıyasla daha başarılı olduğunu göstermektedir.

Tablo 5.4. Önerilen FetalMovNet ve diğer yöntemlerin performanslarının metriklerle karşılaştırılması

Model	Doğruluk	P	R	F1
CNN	0.9153	0.9112	0.9083	0.9098
CNN-LSTM	0.9265	0.9191	0.9228	0.9209
FetalMovNet	0.9887	0.9871	0.9910	0.9891

Alıcı işletim karakteristiği (Receiver operating characteristic, ROC) eğrisi, modelin ultrason videolarındaki fetal hareketleri doğru şekilde sınıflandırma yeteneğini değerlendirmek için kullanılabilir. Doğru pozitif (true pozitif rate) ve yanlış pozitif oranları (false pozitif rate) arasındaki dengeyi gösterir. ROC eğrileri, sınıflandırma performanslarını karşılaştırmak için standartlaştırılmış bir yol sağlar. Eğri altındaki alan (AUC) özet bir metrik olarak kullanılabilir ve daha yüksek bir AUC, hareket sınıfları arasında daha iyi ayırım yapan bir modele işaret eder.



Şekil 5.9. Fetal anatomik yapıların sınıflandırılması için test setindeki her bir anatomik yapı için (a) tipik CNN, (b) CNN-LSTM ve (c) önerilen FetalMovNet mimarilerinin ROC eğrileri ve AUC skorları

Şekil 5.9, test setindeki her bir anatomik yapı için ROC eğrisinden elde edilen AUC değerlerini göstermektedir. Şekil 5.9(a) ve Şekil 5.9(b)'de görülebileceği gibi, test setindeki baş, gövde, kol, el, kalp, bacak ve ayak anatomik yapıları için CNN ve CNN-LSTM için sırasıyla 0.9471 ve 0.9543 ortalama AUC puanı elde edilirken, önerilen FetalMovNet mimarisi (Şekil 5.9(c)) kullanılarak fetüsün aynı anatomik yapıları için ortalama 0.9957 AUC puanı elde edilmiştir. Öte yandan, önerilen FetalMovNet mimarisi kullanıldığında, vücut, bacak, kalp, el ve ayak hareket sınıfları için 1.0 AUC puanları elde edilerek ultrason videolarından fetal hareketlerin başarılı bir şekilde sınıflandırıldığı doğrulanmıştır.

6. TARTIŞMA

Tez çalışması kapsamında, ultrason taramalarında fetal hareketleri içeren özgün bir veriseti hazırlanmıştır ve bu verisetindeki taramalar kullanılarak iki farklı çalışma yürütülmüştür. İlk çalışmada, fetal ultrason (ultrason) videoları kullanılarak fetüsün anatomik yapılarının tanınması ve hareketlerinin tespit edilmesi için YOLOv5 ve LSTM algoritmalarına dayalı hibrit bir derin öğrenme yöntemi önerilmiştir. Ultrason videolarındaki fetal hareketlerin otomatik olarak sınıflandırılması, fetal iyilik halinin değerlendirilmesi ve hamilelik sırasında olası komplikasyonların tespit edilmesi için kritik öneme sahiptir. Tez çalışmasının ikinci kısmında, ultrason video dizilerindeki fetal hareketlerin sınıflandırılmasını iyileştirmek için CNN ve dikkat (attention) mekanizması içeren yeni bir derin öğrenme modeli olan FetalMovNet önerilmiştir.

Fetüs her zaman hareket etmediğinden, fetüs hareketlerinin yeterli netlikte bulunduğu ultrason videoları elde etmek zor bir işlemdir. Tezin ilk çalışması için, nesneye ait tek bir nokta kullanmak yerine sınırlayıcı kutuya ait diğer noktaların da kullanılarak harekete ait daha fazla nokta verisi kayıt edilebilir. Bu verilerin kullanılması hareketi sınıflandırma başarımını arttırabilir. Böylece, ağın bu özelliği kullanılarak anormal hareket desenlerinin tahmin edilmesi sağlanabilir. Ultrason görüntüleri düşük çözünürlüklü görüntüler olduğundan derin öğrenme ağlarıyla işlenmeleri daha az hesaplama yükü oluşturur. Bu yönden değerlendirildiğinde derin öğrenme yöntemleriyle elde edilecek modeller görece daha düşük donanımlarda kullanılabilir modeller olabilir. Ayrıca, bu yaklaşım, fetüs hareketlerinin takibi ve sınıflandırılması ultrason görüntülerini yeni tanıyan tıp öğrencilerinin görüntüleri daha rahat anlamasına destek sağlayabilir. Diğer taraftan, eğer uygulamada anormal hareketlerin bulunduğu ultrason videoları elde edilebilirse bu hareketlerin tahmin edilebileceği değerlendirilmektedir. Ancak, video çekildiği esnada hareketleri tanımayı sağlayacak uygun hareketlerin ortaya çıkmasını beklemek bu yöntemin zorluğudur.

Aslında, literatürde hareket sınıflandırması için yörünge bilgisini kullanan çalışmalar vardır. Ancak ultrason videolarındaki nesnelere yörünge bilgisi kullanılarak sınıflandırılabilirdiği çok fazla çalışma bulunmamaktadır. Çalışmada, fetal hareket yörünge bilgisi normalize edilip LSTM ağında eğitildiğinde, ağın organın hareketlerine uyum sağlayabildiği ve dolayısıyla ultrason videolarındaki nesnelere yörünge bilgisi kullanılarak sınıflandırılabilirdiği görülmüştür. Ayrıca fetal ultrason taramalarında anatomik yapıların hareket ettiği videoların elde edilmesi ve her bir anatomik yapı için yeterli netlikte videoların toplanması zor bir süreçtir. Ayrıca, fetüs her zaman hareket etmediğinden, video elde etme


anında hareketleri tanımak için uygun hareketlerin gerçekleşmesini beklemek de bir başka zorluktur. Fetal videolarda nesnenin tek bir noktasını kullanmak yerine, sınırlayıcı kutunun diğer noktaları kullanılarak hareketin daha fazla nokta verisi toplanabilir. Bu verilerin kullanılması hareketin sınıflandırma performansını artırabilir. Ağın bu özelliğini kullanarak anormal hareket modellerini tahmin etmek mümkündür. Anomalili fetüslerin hareketlerini elde etmek zor bir işlemdir. Ayrıca, hareket anomalilerine neden olan bozukluklar nadirdir, bu nedenle bu tür fetal hareket videolarını toplamak da zordur. Pratikte anormal hareketler içeren ultrason videoları elde edilebilirse, bu hareketlerin tahmin edilebileceği düşünülmektedir. Ayrıca, derin öğrenme modelleri 3B taramalar elde etmek için kullanılabilir. Üretken çekişmeli ağ (generative adversarial network, GAN) bu tür görüntüleri oluşturmak, gerçeğe çok yakın yapay görüntüler elde etmek için kullanılır. GAN ağlarını fetal anatomik yapılara uygulayarak daha yüksek çözünürlüklü anatomik yapı görüntüleri elde etmek mümkün olabilir. Son olarak, fetüs görüntülerinin böyle bir ağ ile yüksek çözünürlüğe dönüştürülmesi, detaylı ultrason gibi sıkıcı işlemlere gerek kalmadan sıradan ultrason cihazları ile daha net görüntüler elde edilmesini sağlayabilir.

Bu tez çalışmasında, ultrason videolarındaki fetal hareketleri sınıflandırmak için tasarlanmış yeni bir derin öğrenme modeli olan FetalMovNet'i de geliştirilmiştir. Model, geleneksel CNN ve CNN-LSTM mimarilerine kıyasla fetal anatomik hareketlerin doğru tespiti ve sınıflandırılmasında önemli gelişmeler sağlayan bir dikkat mekanizması ile geliştirilmiş CNN tabanlı bir mimari kullanmaktadır. FetalMovNet'in en önemli avantajı, modelin fetal hareketle en alakalı uzamsal ve zamansal modellere odaklanmasını sağlayan bir dikkat mekanizmasının kullanılmasıdır. CNN katmanlarıyla bir araya getirilen bu dikkat temelli yaklaşım, video verilerindeki zamansal bağımlılıkları yakalamakta zorlanabilen geleneksel CNN modellerinin sınırlamalarının üstesinden gelerek kareler arasındaki dinamik hareketleri daha doğru bir şekilde sınıflandırabilen bir modelle sonuçlanır. Bir dizi deney sayesinde FetalMovNet'in farklı fetal anatomik yapıları yüksek doğruluk ve güvenilirlikle ayırt edebildiğini gözlemlenmiştir.

Ablasyon çalışması, dikkat mekanizmasının dahil edilmesinin sınıflandırma performansını artırmak için çok önemli olduğunu göstermiştir. Dikkat katmanı kaldırılıp sadece CNN ve tam bağlı katmanlar bırakıldığında, modelin doğruluğu önemli ölçüde azalmış ve karışıklık matrislerimizde gösterildiği gibi çoğu sınıf için AUC değeri de düşmüştür. Buna ek olarak, CNN ve LSTM'nin bir kombinasyonu olan CNN-LSTM mimarisi kullanılarak, performansın tipik CNN'e kıyasla biraz iyileştirildiği gözlemlenmiştir. Ancak CNN-LSTM ile elde edilen sonuçlar yine de önerilen FetalMovNet modelinden daha düşüktür. Buna karşılık,

FetalMovNet'in dikkat katmanı, modelin ilgili görüntü dizilerine ve bölgelerine dinamik olarak odaklanmasını sağlayarak yanlış pozitifleri ve yanlış negatifleri en aza indirerek daha doğru sınıflandırma yapmasını sağlamıştır. Ancak bu sonuçların anlamlı olabilmesi için CNN, CNN-LSTM ve FetalMovNet ile elde edilen sonuçların istatistiksel anlamlılığının değerlendirilmesi ve sonuçların buna göre değerlendirilmesi gerekmektedir. Veriler arasındaki anlamlılığı değerlendirmek için kullanılacak birçok test vardır. Wilcoxon signed-rank testi, iki değişkenin medyanları arasındaki farkı değerlendiren parametrik olmayan bir istatistiksel testtir (Turkan vd., 2025). Bu çalışmada, CNN ve CNN-LSTM ile önerilen FetalMovNet mimarileri kullanılarak elde edilen sonuçların karşılaştırılması ve istatistiksel anlamlılığı için iki taraflı Wilcoxon işaretli sıralama testi kullanılmıştır. Sonuçlar karşılaştırılırken, her model kullanılarak her sınıf için elde edilen makro-ortalama F1-skorlarının ortalamaları dikkate alınmıştır. Tipik CNN ve FetalMovNet'in Wilcoxon işaretli sıralama testi sonuçlarına göre karşılaştırılması 0.012'lik bir p -değeri vermiştir. Öte yandan, CNN-LSTM ve FetalMovNet'in Wilcoxon işaretli sıralama testi sonuçları karşılaştırıldığında p -değeri 0.028 olmuştur. Her iki karşılaştırmada da elde edilen p -değerleri 0.05'ten küçük olduğu için elde edilen sonuçların Wilcoxon işaretli sıralama testine göre istatistiksel olarak anlamlı olduğu söylenebilir.

Bu tez çalışmasında önerilen FetalMovNet mimarisi kullanılarak, fetal anatomik yapıların test setindeki 177 fetal ultrason videosundan 175'i doğru sınıflandırılmıştır. Ancak, Şekil 6.1'deki bazı karelerden de görülebileceği gibi, kafa anatomik yapısına ait fetal hareket içeren 1 ultrason videosu yanlışlıkla gövde olarak sınıflandırılmıştır. Öte yandan, kol sınıfına ait bir başka ultrason videosu da el olarak yanlış sınıflandırılmıştır. Bu fetal hareketlerin önerilen FetalMovNet mimarisi tarafından yanlış tanınmasının nedeni, bu videolardaki sıralı hareket örüntülerinin yanlış tanınan sınıf hareketlerinin örüntülerine benzemesidir.



Şekil 6.1. Önerilen FetalMovNet mimarisi kullanılarak test setindeki yanlış sınıflandırılmış fetal hareketlerin ardışık çerçevelerinin değerlendirilmesi

Önceki çalışmalar, ultrason taramalarından fetal anatomik yapıların tespiti ve ölçümü için çeşitli yaklaşımlar önermiştir. Bu çalışmaların çoğu, çalışmaya özgü orijinal veri kümeleri oluşturmuştur. Bu çalışmalardan birinde Carneiro ve arkadaşları (G. Carneiro vd., 2008: 1342) kafa, gövde, karın, femur ve humerus gibi fetal anatomiye tespit etmek ve ölçmek için olasılıksal bir boosting ağacı kullanmıştır. Cuingnet ve arkadaşları (Cuingnet vd., 2013: 768), fetal kafanın konumunu ortalama 5.8 mm hata ile belirlemek için 3B ultrason görüntülerinden rastgele ormanlar ve şablon deformasyonu kullanmıştır. Öte yandan, Ravishankar ve arkadaşları (Ravishankar vd., 2016: 779) CNN tabanlı bir hibrit yaklaşım kullanarak fetal karın bölgesinin otomatik segmentasyonunu sağlamıştır. Sinclair ve arkadaşları (Sinclair vd., 2018: 714), 2B ultrason görüntüleri üzerinde CNN mimarisi kullanarak fetal baş biyometrisinin segmentasyonunu ve tespitini önermiştir. Alzubaidi ve arkadaşları (Alzubaidi vd., 2024: 281) ultrason taramalarından fetal baş biyometrisinin segmentasyonu için FetSAM derin öğrenme modelini önermiştir. Ayrıca, fetal ultrason taramalarında kalite değerlendirmesi için önerilen çalışmalar (Wu vd., 2017: 1336) ve standart düzlem sınıflandırması için ultrason verilerinde veri artırımı için önerilen çalışmalar (Lee vd., 2021: 729) bulunmaktadır. Ayrıca, önceki çalışmalarımızdan birinde (Dandıl vd., 2021: 208) YOLOv5 kullanarak fetal ultrason taramalarında kafa, kol, kalp ve gövde için anatomik düzlem tanıma sağlamıştır. Diğer çalışmamızda (Turkan vd., 2023: 1) ise, YOLOv5 ve LSTM kullanarak gövde, kafa, kol ve kalp gibi anatomik yapılar için yörüngelerden fetal hareket tespiti sağlanmıştır. Bu çalışmada, önceki çalışmalarımızdan farklı olarak, fetal ultrason videolarından anatomik yapıların tespiti ile fetal hareketin sınıflandırılması, önerilen yeni bir mimari olan FetalMovNet (Turkan vd., 2025) kullanılarak gerçekleştirilmiştir.

FetalMovNet modelinin sonuçları, Tablo 6.1'de gösterildiği gibi, fetal anatomik yapıların tespiti ve sınıflandırılması için daha önce önerilen mevcut çalışmalarla karşılaştırılmıştır. CNN ve benzeri mimariler önceki çalışmalarda fetal anatomik yapıları başarılı bir şekilde tespit etmek ve sınıflandırmak için kullanılmış olsa da, sınıflandırma performansının belirli bir doğrulukta kaldığı ve bu yöntemlerin genellikle hareketlerin anatomik bağlamını anlamaktan ziyade temel sınıflandırmaya odaklandığı görülmektedir. Buna karşılık FetalMovNet modeli, dikkat mekanizması aracılığıyla hem uzamsal hem de zamansal özellikleri etkili bir şekilde öğrenerek ortalama 0.9887 doğrulukla diğer yaklaşımlardan daha iyi performans göstermektedir. Bu sonuçlar, önerilen modelin yalnızca fetal hareketin tespitine değil, aynı zamanda anatomik yapıların doğru sınıflandırılmasına da önemli bir katkı sağladığını göstermektedir.

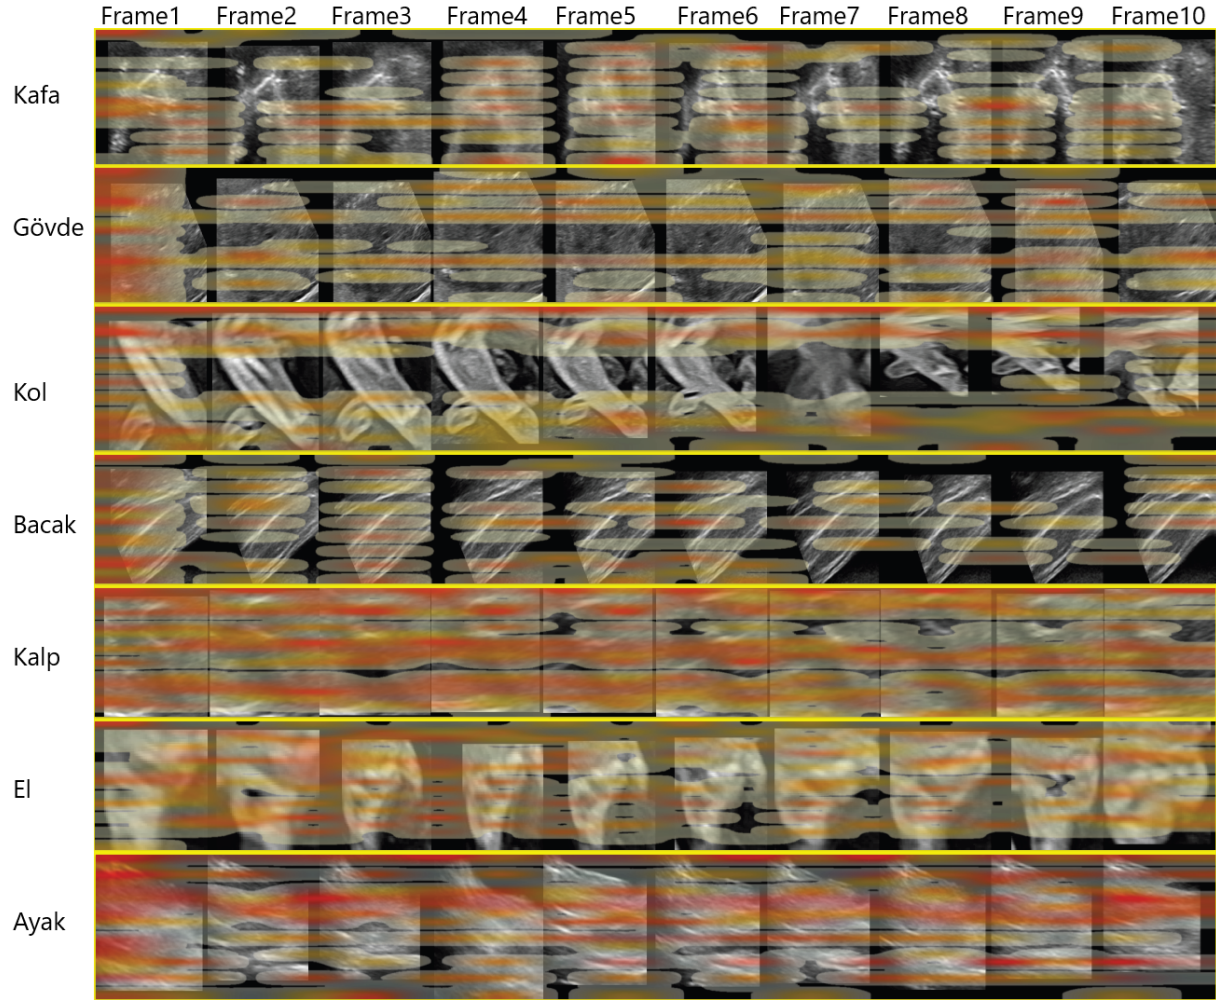
Tablo 6.1. FetalMovNet modelinin sonuçlarının, fetal anatomik yapıların tanınması ve sınıflandırılması için daha önce önerilen mevcut çalışmalarla karşılaştırılması

Çalışma ve Yılı	Veri Seti	Veri Sayısı	Metot	Fetüs Yapılarının Değerlendirilmesi	Anatomik	Performans
(Linares vd., 2004: 1147)	Orijinal veri seti	101 ultrason görüntüsü	Relief-F yöntemiyle özellik seçimi yapılan k-NN (k-nearest neighbors) tabanlı model	Plasenta ultrason görüntüleri kullanarak doku sınıflandırması.		0.6071
(Yağub vd., 2012: 1555)	Orijinal veri seti	40 3D ultrason görüntüsü	Rastgele ormanlar (random forests) tabanlı ayırt edici model	Fetal beyin yapıların otomatik tespiti.		0.929
(Yu vd., 2017: 874)	Orijinal veri seti	1735 ultrason görüntüsü	Derin evrişimli ağlar (DCNN)	Fetal yüz standart düzleminin tanınması		0.9699
(Gao vd., 2016: 787)	Orijinal veri seti	323 fetal ultrason videosu	CNN	Fetüs kafatası, karın, kalp gibi anatomik yapıların tanınması		0.915
(Yu vd., 2017: 874)	Orijinal veri seti (FFSP)	7267 ultrason görüntü	Derin CNN	Fetal yüz için standart düzlem tanıma		0.9653
(Lin vd., 2019: 101548)	Orijinal veri seti	1771 ultrason görüntüsü	Daha hızlı bir R-CNN kullanarak çoklu görev öğrenme çerçevesi	Fetal kafanın sınıflandırılması		0.9625
(Burgos-Artizzu vd., 2020: 10200)	Orijinal veri seti	12400 ultrason görüntüsü	Çeşitli CNN Mimarileri	Karın, beyin, femur, rahim ağzı, göğüs ve diğerleri gibi anne-fetal düzlemlerin sınıflandırılması.		0.936
(Qu vd., 2020: 83821)	Orijinal veri seti	19142 ultrason görüntüsü	Farksal CNN	Fetal beyinde standart düzlem tanıma		0.9311
(B. Zhang vd., 2021: e24427)	Orijinal veri seti	4101 ultrason görüntüsü	CNN-temelli yaklaşımlar	Baş, karın ve kalp gibi fetal standart düzlemlerin değerlendirilmesi.		0.9671
(Li vd., 2024: 107741)	Orijinal veri seti (video)	3360 2D fetal ultrason görüntüsü	FHUSP-NET (YOLO tabanlı derin öğrenme mimarisi)	Kalp anatomik yapısı için fetal standart düzlem tanıma.		0.964
(Yasrab vd., 2024: 805)	PULSE veri seti	250 ultrason videosu	CNN	Fetal doku tanıma ve fetal biyometri ölçümü		0.87
FetalMovNet	Orijinal ultrason veri seti (video)	587 (her biri 10 video karesi içeriyor)	FetalMovNet	Baş, vücut, kalp, kol, ayak, bacak ve el gibi fetal anatomik yapıların otomatik sınıflandırılması, hareket tanıma		0.9887

Derin öğrenme modellerinin klinikte benimsenmesi için radyologlara ve kadın doğum uzmanlarına açıklanabilir olması gerekir. Dikkat mekanizmaları doğruluğu artırırken, klinisyenlerin otomatik kararlara güvenmesi bazen zordur. Bu nedenle, otomatik sistemin nasıl karar verdiğini görselleştirmek sürecin anlaşılabilirliğine katkıda bulunur. Bu çalışmada, önerilen FetalMovNet mimarisinin ultrason sekanslarını kullanarak fetal hareketlerin sınıflandırılması için hangi uzaysal-zamansal özellikleri dikkate aldığını göstermek ve bu önemli özelliklerin ısı haritalarını oluşturmak için ayırt edici bir yerelleştirme tekniği olan gradyan ağırlıklı sınıf aktivasyon haritalaması (Grad-CAM) kullanılmıştır. Grad-CAM, belirli bir sınıfın tahmin edilmesini sağlamak amacıyla bir görüntü veya video karesinin kilit bölgelerini vurgulamak için sınıflandırma problemlerinde yaygın olarak kullanılmaktadır (Tang ve Chen, 2009: 648; Turkan vd., 2025). Buna ek olarak, Grad-CAM görüntüler üzerindeki herhangi bir CNN modeline uyarlanabilir ve görüntülerin görsel açıklamalarının oluşturulması yoluyla daha şeffaf bir ısı haritası sağlayabilir (Turkan vd., 2025). Grad-CAM, görüntünün/çerçevenin belirli bir sınıfın tahminine katkıda bulunan kilit bölgelerini vurgulamak için bir mekanizma sağlar. Çevredeki fetal anatomik yapıların dikkatini dağıtmak yerine Grad-CAM, modelin fetal hareketlerin doğru sınıflandırılmasına en çok katkıda bulunan bölgelere dikkatini artırmasını ister. Grad-CAM, ultrason görüntülerinde fetal hareket sınıflandırmasına katkıda bulunan göze çarpan bölgeleri vurgular ve klinisyenlerin hangi anatomik özelliklerin model tahminlerini etkilediğini anlamalarına yardımcı olur. Grad-CAM, ultrason görüntüleri üzerine bindirilmiş uzamsal ısı haritaları sağladığından, hangi zamansal karelerin fetal hareket sınıflandırmasına en çok katkıda bulunduğunu gösterir. Şekil 6.2, FetalMovNet'in Grad-CAM'li ultrason dizilerindeki kalp, gövde, kol, bacak, kafa, el ve ayak gibi fetal anatomik yapılar için özellik çıktılarının ısı haritasını göstermektedir. Grad-CAM ile ilgilenilen bölgelerin özelliklerinin, sıralı 10 kare dizilerdeki hareketlerin ısı haritalarına benzer olduğu görülebilir. Sonuç olarak, FetalMovNet'in sınıflandırma sonucu ile Grad-CAM tarafından çıkarılan ısı haritası özellikleri uyumludur. Grad-CAM'in FetalMovNet mimarisine entegre edilmesiyle model, fetal anatomik yapıların karakteristik ayrıntılarını daha iyi anlama ve vurgulama yeteneği kazanmıştır.

FetalMovNet, doğruluğu artıran ancak hesaplama gereksinimlerini artırabilen CNN tabanlı özellik çıkarma ve bir dikkat mekanizmasını entegre eder. Bu nedenle, test setindeki veri sayısı arttıkça, gerçek zamanlı klinik uygulamalarda hesaplama süresi artabilir. Modelin ultrason görüntülerini işleme hızı kritik öneme sahiptir. Anlamlı klinik bilgiler sağlamak için FetalMovNet gerçek zamanlı veya gerçek zamana yakın hızlarda çalışmalıdır. Önerilen

FetalMovNet modelinin test setindeki toplam 177 ardışık 10 karelik ultrason sekansı üzerindeki toplam test/hesaplama süresi 11.6 saniyedir. Bu, tek bir ultrason dizisi için ortalama 65 ms ile sonuçlanır. Dolayısıyla tek bir ultrason karesi için gecikme süresi 6.5 ms'dir. Gecikme gerçek zamanlı uygulamalar için kritiktir ve her bir kare için ortalama süre 10 ms - 50 ms olarak kabul edilebilir. Bu nedenle FetalMovNet gerçek zamanlı gereksinimleri karşılar (kare başına ≤ 100 ms gecikme) ve gerçek zamanlı izleme için ultrason makinelerine entegre edilebilir. Öte yandan, üst düzey GPU'lar kullanılarak gerçek zamanlı çıkarım elde edilebilir.



Şekil 6.2. Grad-CAM ile ultrason sekanslarında kafa, kalp, gövde, kol, bacak, el ve ayak gibi fetal anatomik yapılar için FetalMovNet'in özellik çıktılarının ısı haritası

Anomali bulunan fetüslere ait hareketlerin elde edilmesi zor bir işlemdir. Hareket anomalisine sebep olan rahatsızlıklar nadir görülür. Bu sebeple bu tür fetüs hareket videolarının toplanması zor bir işlemdir. Fetüs hareketlerinin riskli gebeliklerin tespitinde kullanılabileceğini göstere çalışmalar bulunmaktadır(Gorthi vd., 2009: 6222). Bu amaçla farklı fetüs dokularının hareketlerinin riskli gebelik tahmininde kullanılabilmesi için daha fazla genişletilmiş bir veri seti ve farklı patolojik durumlarla test edilmesi modelin geliştirilme

yeteneğine katkı sağlayabilir. Bu amaçla farklı patolojik vakalar ait hareketlerin etiketlenmesi gerekir. Diğer taraftan, derin öğrenme modelleri üç boyutlu görüntüler elde etmek için kullanılabilir. GAN ağları bu türden görüntüler oluşturmak, gerçeğe çok benzeyen yapay görüntüler elde etmek için kullanılmaktadır (Yang vd., 2021: 672). GAN ağları fetüs organlarına uygulanarak daha yüksek çözünürlüklü organ görüntüleri elde etmek mümkün olabilir. Fetüs görüntülerinin böyle bir ağ ile yüksek çözünürlüğe dönüştürülmesi detaylı ultrason gibi meşakkatli işlemlere gerek kalmadan sıradan ultrason cihazları ile daha net görüntülere ulaşılabilmesini sağlayabilir. Ultrason görüntü kalitesi genellikle düşük olduğundan GAN mimarisi kullanılarak ultrason fetüs görüntülerinin iyileştirilmesi sağlanabilir. Farklı fetüs rahatsızlıklarına ait hareketler toplandığında fetüs anomalilerin erken teşhisinde hareketler değerlendirilebilir.

7. SONUÇLAR

Derin öğrenme yöntemleri son yıllarda tıbbi verilerin işlenmesi ve değerlendirilmesinde yaygın olarak kullanılmaktadır. Tıbbi görüntü ve videoların analizinde bir araç olarak kullanılan bilgisayar destekli sistemler, teşhis sürecini kolaylaştırabilmekte ve uzmanların karar verme aşamalarında doğruluğun artırılmasına katkı sağlayabilmektedir. Ayrıca tecrübe ve uzmanlık gerektiren tıbbi verilerin değerlendirilmesi derin öğrenme yardımıyla gerçekleştirilerek teşhis ve tedavide kolaylık sağlamaktadır. Tez çalışması kapsamında, ultrason taramalarında fetal hareketleri içeren özgün bir veri seti hazırlanmıştır ve bu veri setindeki taramalar kullanılarak iki farklı çalışma yürütülmüştür:

- İlk çalışmada, fetal ultrason (US) videoları kullanılarak fetüsün anatomik yapılarının tanınması ve hareketlerinin tespit edilmesi için YOLOv5 ve LSTM algoritmalarına dayalı hibrit bir derin öğrenme yöntemi önerilmiştir. Çalışmada, fetal hareketleri içeren ultrason videolarından oluşan veri kümesinde etiketlenen veriler üzerinde fetüsün anatomik yapıları belirlenmekte ve hareketleri takip edilmektedir. Deneysel analizlerde fetüsün kalp, kafa ve gövde gibi anatomik yapılarının hareketleri takip edilerek hareket yörünge örüntüleri çıkarılmıştır. Son aşamada ise fetal anatomik yapıların tespiti ve sınıflandırılması LSTM derin öğrenme mimarisi ile gerçekleştirilmiştir. Deneysel çalışmalarda, eğitim verileriyle tahmin için ortalama karesel hata (mean square error, MSE) değeri 0.0069 olarak başarılıken, doğrulama (test) verileri için ortalama MSE değeri 0.0097 olarak hesaplanmıştır. Buradan, tahmin sonuçlarının genel olarak gerçek verilerle uyumlu olduğu ve LSTM ağının hem eğitim hem de test setlerinden fetüse ait anatomik yapıların hareketlerinin özelliklerini tanıyabildiği görülebilir.
- Ultrason videolarındaki fetal hareketlerin otomatik olarak sınıflandırılması, fetal iyilik halinin değerlendirilmesi ve hamilelik sırasında olası komplikasyonların tespit edilmesi için kritik öneme sahiptir. Tez çalışmasının ikinci kısmında, ultrason video dizilerindeki fetal hareketlerin sınıflandırılmasını iyileştirmek için CNN ve dikkat (attention) mekanizması içeren yeni bir derin öğrenme modeli olan FetalMovNet önerilmiştir. Model, özellik çıkarımı için konvolüsyonel sinir ağlarını (CNN) ve uzamsal-zamansal örüntüleri yakalamak için bir dikkat mekanizmasını entegre ederek fetal hareketlerin sınıflandırma performansını önemli ölçüde artırmaktadır. FetalMovNet'i değerlendirmek için, yedi farklı anatomik yapıda (kafa, gövde, kol, el, kalp, bacak ve ayak) ultrasondaki fetal hareketleri içeren yeni bir veri kümesi oluşturulmuştur. Deneysel sonuçlar, FetalMovNet'in 0.9887 doğruluk (accuracy), 0.9871 kesinlik

(precision), 0.9910 geri çağırma (recall) ve 0.9891 F1 puanı (F1-score) elde ederek gelişmiş CNN ve CNN-LSTM mimarilerinden daha iyi performans gösterdiğini doğrulamaktadır. Ablasyon çalışmaları, FetalMovNet'in CNN için 0.9471 ve CNN-LSTM için 0.9543 ile karşılaştırıldığında 0.9957'lik bir eğri altı alan (AUC) puanı elde etmesiyle dikkat mekanizmasının etkinliğini doğrulamaktadır. Önerilen FetalMovNet modeli, gerçek zamanlı fetal hareket izleme için sağlam ve klinik olarak uygulanabilir bir araç sağlayarak manuel değerlendirme ihtiyacını azaltabileceği ve doğum öncesi bakımı iyileştirebileceği değerlendirilmektedir.

Tezde, ultrason videolarından kafa, gövde, kol, el, ayak, bacak ve kalp gibi fetal anatomik yapıları tespit etmek ve bu yapıların fetal hareketlerini sınıflandırmak için dikkat mekanizmasına dayalı önerilen bir derin öğrenme modeli olan FetalMovNet geliştirilmiştir. Ultrason videoları dizisindeki her seviyede özellikleri çıkarmak için bir CNN ağı kullanılmıştır. Dikkat katmanı, hareketlerin neden olduğu farklılıklara odaklanarak video kareleri arasındaki önemli bağlantıları yakalamak için kullanılmıştır. Bu çalışmanın sonuçları FetalMovNet'in fetal hareket sınıflandırması için etkili bir araç olduğunu ve geleneksel CNN yaklaşımlarından daha yüksek doğruluk ve sağlamlık sunduğunu göstermektedir. FetalMovNet, fetal hareket değerlendirmesinin güvenilir ve yorumlanabilir modellerle otomasyonu sayesinde doğum öncesi bakımı iyileştirme ve fetal izlemeyi daha doğru, erişilebilir ve objektif hale getirme potansiyeline sahiptir.

Fetal hareketler fetal iyilik halinin önemli bir göstergesidir. Bu çalışmada fetal hareketlerin tanınması, hamilelik sırasında fetal refahın izlenmesine yardımcı olabilir. Bu çalışma, otomatik fetal sağlık değerlendirmesi için bir temel oluşturmanın yanı sıra, tıbbi görüntü analizinde dikkat temelli derin öğrenme modellerinin değerini vurgulamaktadır. Daha fazla doğrulama ve optimizasyon ile FetalMovNet, klinik uygulamada vazgeçilmez bir araç haline gelebilir ve klinisyenlerin fetal hareketin zamanında ve doğru analizi yoluyla gebelik sonuçlarını iyileştirmelerine yardımcı olabilir. FetalMovNet'in klinik etkileri umut vericidir. Geleneksel fetal sağlık takibinde, fetal hareketin değerlendirilmesi büyük ölçüde subjektif ve manuel gözleme dayanır, bu da hataya ve zaman kısıtlamalarına açıktır. FetalMovNet, bu süreci otomatikleştirerek klinisyenlerin fetal iyilik halini daha hızlı ve daha doğru bir şekilde değerlendirmelerine yardımcı olabilir ve sürekli manuel izleme ihtiyacını azaltabilir. Anormal fetal hareket örüntüleri fetal sıkıntı, nörolojik ve kardiyak anormallikler gibi durumlara işaret edebilir. Buna ek olarak, yüksek doğruluk ve hassasiyetiyle FetalMovNet, klinisyenleri anormal hareket modellerine karşı uyarma potansiyeline sahiptir ve fetal sıkıntı veya gelişimsel

sorunların mevcut olabileceği durumlarda daha erken müdahaleye olanak sağlar. Buna ek olarak, anne adayları genellikle fetal aktivite konusunda endişelenmekte ve öznel hareket algılarına güvenmektedir. FetalMovNet objektif geri bildirim sağlayarak gereksiz endişeyi azaltabilir ve anormalliklerin erken tespit edilmesine yardımcı olabilir.

Bu çalışmada ultrason sekanslarından fetal hareketlerin sınıflandırılması için önerilen FetalMovNet modelinin çeşitli güçlü yönleri vardır. İlk olarak, model doğruluk, kesinlik, geri çağırma ve F1-skoru için daha yüksek performans elde ederek, güncel CNN ve CNN-LSTM modelleriyle karşılaştırıldığında mükemmel sınıflandırma kabiliyetine işaret etmektedir. Öte yandan, FetalMovNet'e bir dikkat mekanizmasının entegre edilmesi, daha yüksek bir AUC skoru ile uzamsal-zamansal özellik çıkarımını iyileştirmektedir. Ayrıca, çalışmada yedi farklı anatomik hareket içeren yeni bir veri kümesi sunulmuş ve fetal hareketlerin farklı bir şekilde temsil edilmesi sağlanmıştır. Bu veri kümesi kullanılarak, FetalMovNet'in farklı anatomik hareketlere iyi genelleme yaptığı gösterilmiş ve gerçek zamanlı klinik izleme için bir araç olarak potansiyeli vurgulanmıştır.

Güçlü yönlerine rağmen FetalMovNet'in kabul edilmesi gereken birkaç sınırlaması vardır. İlk olarak, model belirli bir veri kümesi üzerinde eğitilmiştir, bu da farklı popülasyonlar ve görüntüleme kurulumları arasında genelleştirilebilirliğini sınırlayabilir. İkinci olarak, deneysel çalışmalarda, test setindeki tek bir ultrason dizisi için ortalama hesaplama süresi 65 ms'dir. Dikkat mekanizmalarının ve derin CNN'lerin kullanımı, hesaplama yükünü artırarak standart ultrason cihazlarında gerçek zamanlı dağıtım potansiyel olarak zorlaştırmaktadır. Son olarak, veri kümesindeki video karesi dizileri 10 kareyle sınırlıdır. Bu durumda, birden fazla kareye yayılan uzun süreli hareketleri tespit etmek zor olabilir.

Gelecekteki araştırmalar bu çalışmayı çeşitli şekillerde genişletebilir. İlk olarak, FetalMovNet'i daha kapsamlı ve daha geniş bir fetal değerlendirme yelpazesine uyarlanabilir hale getirmek için veri setine ek anatomik sınıflar ve hareket modelleri eklenebilir. Buna ek olarak, gelecekteki uygulamalar, doğruluktan ödün vermeden çıkarım süresini azaltmak için modelin optimize edilmesinden faydalanabilir ve böylece kaynak kısıtlı ortamlarda kullanılmasını sağlayabilir. Ayrıca, gelecekteki çalışmalar, karmaşık hareket dizilerinin ele alınmasında ek iyileştirmeler sağlayabilecek öz dikkat veya çoklu kafa dikkati gibi alternatif dikkat mekanizmalarının kullanımını araştırabilir. Öte yandan, fetal ultrason videolarının ayrıntılı analizleri, farklı hastalık türlerinin karakteristik hareketlerinin belirlenmesine yardımcı olabilir. Oluşturulan veri setinin zenginleştirilmesi, hareket analizinin farklı görevler için kullanılmasına olanak sağlayabilir. Son olarak, ultrason videolarındaki anatomik yapıların

hareketinin doğası normal hareketten farklıdır. Videodaki hareket, kullanıcının ultrason cihazını nasıl kullandığına ve cihazın anatomik yapıları algılama kalitesine bağlı olarak değişebilir. Hareket sadece anatomik yapının kendisinden değil, aynı zamanda cihaz kullanıcısının hareketlerinden de kaynaklanabilir.

KAYNAKÇA

Ahmed, M., & Noble, J. A. (2016). Fetal ultrasound image classification using a bag-of-words model trained on sonographers' eye movements. *Procedia Computer Science*, 90, 157.

Alzubaidi, M., Shah, U., Agus, M., & Househ, M. (2024). FetSAM: Advanced Segmentation Techniques for Fetal Head Biometrics in Ultrasound Imagery. *IEEE Open Journal of Engineering in Medicine Biology*, 5, 281.

Arnaout, R., Curran, L., Zhao, Y., Levine, J., Chinn, E., & Moon-Grady, A. (2020). Expert-level prenatal detection of complex congenital heart disease from screening ultrasound using deep learning. *medRxiv*.

Azad, R., Niggemeier, L., Hüttemann, M., Kazerouni, A., Aghdam, E. K., Velichko, Y., Bagci, U., & Merhof, D. (2024). *Beyond self-attention: Deformable large kernel attention for medical image segmentation*. Paper presented at the Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision.

Bai, Y. (2016). *Object tracking & fetal signal monitoring*: Southern Illinois University at Carbondale.

Baumgartner, C. F., Kamnitsas, K., Matthew, J., Fletcher, T. P., Smith, S., Koch, L. M., Kainz, B., & Rueckert, D. (2017). SonoNet: real-time detection and localisation of fetal standard scan planes in freehand ultrasound. *IEEE transactions on medical imaging*, 36(11), 2204.

Bekedam, D., Visser, G., De Vries, J., & Prechtl, H. (1985). Motor behaviour in the growth retarded fetus. *Early Human Development*, 12(2), 155.

Bewley, A., Ge, Z., Ott, L., Ramos, F., & Upcroft, B. (2016). *Simple online and realtime tracking*. Paper presented at the 2016 IEEE international conference on image processing (ICIP).

Birnholz, J. C., Stephens, J. C., & Faria, M. (1978). Fetal movement patterns: a possible means of defining neurologic developmental milestones in utero. *American Journal of Roentgenology*, 130(3), 537.

Brattain, L. J., Telfer, B. A., Dhyani, M., Grajo, J. R., & Samir, A. E. (2018). Machine learning for medical ultrasound: status, methods, and future opportunities. *Abdominal radiology*, 43, 786.

Burgos-Artizzu, X. P., Coronado-Gutiérrez, D., Valenzuela-Alcaraz, B., Bonet-Carne, E., Eixarch, E., Crispi, F., & Gratacós, E. (2020). Evaluation of deep convolutional neural networks for automatic classification of common maternal fetal ultrasound planes. *Scientific Reports*, 10(1), 10200.

Carneiro, G., Georgescu, B., Good, S., & Comaniciu, D. (2007). *Automatic fetal measurements in ultrasound using constrained probabilistic boosting tree*. Paper presented at the Medical Image Computing and Computer-Assisted Intervention–MICCAI 2007: 10th International Conference, Brisbane, Australia, October 29–November 2, 2007, Proceedings, Part II 10.

Carneiro, G., Georgescu, B., Good, S., & Comaniciu, D. (2008). Detection and measurement of fetal anatomies from ultrasound images using a constrained probabilistic boosting tree. *IEEE Trans Med Imaging*, 27(9), 1342.

CDC. (2022). World Birth Defects Day 2023: Global Efforts to Raise Awareness and Support Families. [Erişim Tarihi: 6.03.2025, <https://archive.cdc.gov/#/details?url=https://www.cdc.gov/globalhealth/stories/2022/world-birth-defects-day-2022.html>].

Chen, H., Dou, Q., Ni, D., Cheng, J.-Z., Qin, J., Li, S., & Heng, P.-A. (2015). *Automatic fetal ultrasound standard plane detection using knowledge transferred recurrent neural networks*. Paper presented at the International Conference on Medical Image Computing and Computer-Assisted Intervention.

Chen, K., Li, H., Li, C., Zhao, X., Wu, S., Duan, Y., & Wang, J. (2022). An automatic defect detection system for petrochemical pipeline based on cycle-gan and yolo v5. *Sensors*, 22(20), 7907.

Chen, L. (2021). *Deep learning and practice with mindspore*: Springer Nature.

Chen, X., He, M., Dan, T., Wang, N., Lin, M., Zhang, L., Xian, J., Cai, H., & Xie, H. (2020). Automatic measurements of fetal lateral ventricles in 2d ultrasound images using deep learning. *Frontiers in neurology*, 11, 526.

Copeland, W., & Chiang, C.-C. (2012). *A method for fetal assessment using data mining and machine learning*. Paper presented at the 2012 International Conference on Information Security and Intelligent Control.

- Corbetta, M., & Shulman, G. L.** (2002). Control of goal-directed and stimulus-driven attention in the brain. *Nature reviews neuroscience*, 3(3), 201.
- Cuingnet, R., Somphone, O., Mory, B., Prevost, R., Yaqub, M., Napolitano, R., Papageorghiou, A., Roundhill, D., Noble, J. A., & Ardon, R.** (2013). *Where is my baby? A fast fetal head auto-alignment in 3D-ultrasound*. Paper presented at the 2013 IEEE 10th International Symposium on Biomedical Imaging.
- Çakır, D., Say, A., & Özbek, H.** (2022). *Fetal Hareket Sayımı ve Bağlanma*. Paper presented at the Karadeniz 11th International Conference On Applied Sciences, Rize, Türkiye.
- Dandıl, E., Turkan, M., Urfalı, F. E., Bıyık, İ., & Korkmaz, M.** (2021). Fetal Movement Detection and Anatomical Plane Recognition using YOLOv5 Network in Ultrasound Scans. *Avrupa Bilim ve Teknoloji Dergisi*(26), 208.
- Dozen, A., Komatsu, M., Sakai, A., Komatsu, R., Shozu, K., Machino, H., Yasutomi, S., Arakaki, T., Asada, K., & Kaneko, S.** (2020). Image Segmentation of the Ventricular Septum in Fetal Cardiac Ultrasound Videos Based on Deep Learning Using Time-Series Information. *Biomolecules*, 10(11), 1526.
- Dudley, N., & Chapman, E.** (2002). The importance of quality management in fetal measurement. *Ultrasound in Obstetrics Gynecology*, 19(2), 190.
- Feng, S., Zhou, S. K., Good, S., & Comaniciu, D.** (2009). *Automatic fetal face detection from ultrasound volumes via learning 3D and 2D information*. Paper presented at the 2009 IEEE Conference on Computer Vision and Pattern Recognition.
- Fiorentino, M. C., Villani, F. P., Di Cosmo, M., Frontoni, E., & Moccia, S.** (2023). A review on deep-learning algorithms for fetal ultrasound-image analysis. *Medical Image Analysis*, 83, 102629.
- Gao, Y., Maraci, M. A., & Noble, J. A.** (2016). *Describing ultrasound video content using deep convolutional neural networks*. Paper presented at the 2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI).
- Garcia-Canadilla, P., Sanchez-Martinez, S., Crispi, F., & Bijns, B.** (2020). Machine learning in fetal cardiology: What to expect. *Fetal diagnosis therapy*, 47(5), 363.
- Goodfellow, I., Bengio, Y., & Courville, A.** (2016). *Deep learning*: MIT press.

- Gorthi, A., Firtion, C., & Vepa, J.** (2009). *Automated risk assessment tool for pregnancy care*. Paper presented at the 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society.
- Hochreiter, S., & Schmidhuber, J.** (1997). Long short-term memory. *Neural computation*, 9(8), 1735.
- Hooker, D.** (1943). Reflex activities in the human fetus.
- Huang, Q., Zhang, F., & Li, X.** (2018). Machine learning in ultrasound computer-aided diagnostic systems: a survey. *BioMed research international*, 2018.
- Ishikawa, G., Xu, R., Ohya, J., & Iwata, H.** (2019). *Detecting a Fetus in Ultrasound Images using Grad CAM and Locating the Fetus in the Uterus*. Paper presented at the ICPRAM.
- Jang, J., Kwon, J.-Y., Kim, B., Lee, S. M., Park, Y., & Seo, J. K.** (2017). CNN-based estimation of abdominal circumference from ultrasound images. *arXiv preprint arXiv:1702.02741*.
- Jocher, G., Chaurasia, A., Stoken, A., Borovec, J., Kwon, Y., Michael, K., Fang, J., Yifu, Z., Wong, C., & Montes, D.** (2022). ultralytics/yolov5: v7. 0-yolov5 sota realtime instance segmentation. *Zenodo*.
- Kaliappan, J., Bagepalli, A. R., Almal, S., Mishra, R., Hu, Y.-C., & Srinivasan, K.** (2023). Impact of Cross-validation on Machine Learning models for early detection of intrauterine fetal demise. *Diagnostics*, 13(10), 1692.
- Karadavut, K. İ.** (2011). Serebral Palsinin Erken Tanısında Hassas Bir Metot; Genel Hareketlerin Değerlendirilmesi. *Turkiye Klinikleri Journal of Pediatrics*, 20(1), 47.
- Kaur, M., Singh, D., Alzubi, A. A., Shankar, A., & Rawat, U.** (2024). DARNet: Deep Attention Module and Residual Block-Based Lung and Colon Cancer Diagnosis Network. *IEEE Journal of Biomedical and Health Informatics*.
- Kuzu, A., & Santur, Y.** (2023). Early diagnosis and classification of fetal health status from a fetal cardiotocography dataset using ensemble learning. *Diagnostics*, 13(15), 2471.
- Lee, L. H., Gao, Y., & Noble, J. A.** (2021). *Principled ultrasound data augmentation for classification of standard planes*. Paper presented at the International Conference on Information Processing in Medical Imaging.

- Lei, B., Zhuo, L., Chen, S., Li, S., Ni, D., & Wang, T.** (2014). *Automatic recognition of fetal standard plane in ultrasound image*. Paper presented at the 2014 IEEE 11th International Symposium on Biomedical Imaging (ISBI).
- Li, F., Li, P., Wu, X., Zeng, P., Lyu, G., Fan, Y., Liu, P., Song, H., & Liu, Z.** (2024). FHUSP-NET: a multi-task model for fetal heart ultrasound standard plane recognition and key anatomical structures detection. *Computers in Biology Medicine*, 168, 107741.
- Lin, Z., Li, S., Ni, D., Liao, Y., Wen, H., Du, J., Chen, S., Wang, T., & Lei, B.** (2019). Multi-task learning for quality assessment of fetal head ultrasound images. *Medical Image Analysis*, 58, 101548.
- Linares, P., McCullagh, P. J., Black, N. D., & Dornan, J.** (2004). *Feature selection for the characterization of ultrasonic images of the placenta using texture classification*. Paper presented at the 2004 2nd IEEE International Symposium on Biomedical Imaging: Nano to Macro (IEEE Cat No. 04EX821).
- Liu, S., Wang, Y., Yang, X., Lei, B., Liu, L., Li, S. X., Ni, D., & Wang, T.** (2019). Deep Learning in Medical Ultrasound Analysis: A Review. *Engineering*, 5(2), 261.
- Liu, W., Wang, Z., Zhou, B., Yang, S., & Gong, Z.** (2021). *Real-time signal light detection based on yolov5 for railway*. Paper presented at the IOP conference series: Earth and environmental science.
- Looney, P., Stevenson, G. N., Nicolaides, K. H., Plasencia, W., Molloholli, M., Natsis, S., & Collins, S. L.** (2017). *Automatic 3D ultrasound segmentation of the first trimester placenta using deep learning*. Paper presented at the 2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017).
- Lüchinger, A. B., Hadders-Algra, M., Van Kan, C. M., & De Vries, J. I.** (2008). Fetal onset of general movements. *Pediatric research*, 63(2), 191.
- Majd, M., & Safabakhsh, R.** (2020). Correlational convolutional LSTM for human action recognition. *Neurocomputing*, 396, 224.
- Malathi, G., & Shanthi, V.** (2009). *Wavelet based features for ultrasound placenta images classification*. Paper presented at the 2009 second international conference on emerging trends in engineering & technology.
- Malta, A., Mendes, M., & Farinha, T.** (2021). Augmented reality maintenance assistant using yolov5. *Applied Sciences*, 11(11), 4758.

Miao, Y., Gowayed, M., &Metze, F. (2015). *EESEN: End-to-end speech recognition using deep RNN models and WFST-based decoding*. Paper presented at the 2015 IEEE Workshop on Automatic Speech Recognition and Understanding (ASRU).

Nawaz, T., Cavallaro, A., &Rinner, B. (2014). *Trajectory clustering for motion pattern extraction in aerial videos*. Paper presented at the 2014 IEEE International Conference on Image Processing (ICIP).

Ouyang, D., He, B., Ghorbani, A., Yuan, N., Ebinger, J., Langlotz, C. P., Heidenreich, P. A., Harrington, R. A., Liang, D. H., &Ashley, E. A. (2020). Video-based AI for beat-to-beat assessment of cardiac function. *nature*, 580(7802), 252.

Park, K., Choi, Y., Choi, W. J., Ryu, H.-Y., &Kim, H. (2020). LSTM-based battery remaining useful life prediction with multi-channel charging profiles. *IEEE Access*, 8, 20786.

Patra, A., &Noble, J. A. (2019). *Multi-anatomy localization in fetal echocardiography videos*. Paper presented at the 2019 IEEE 16th international symposium on biomedical imaging (ISBI 2019).

Plotka, S. S., Grzeszczyk, M. K., Szenejko, P. I., Żebrowska, K., Szymecka-Samaha, N. A., Łęgowik, T., Lipa, M. A., Kosińska-Kaczyńska, K., Brawura-Biskupski-Samaha, R., Işgum, I. J. A. j. o. o., &MFM, g. (2023). Deep learning for estimation of fetal weight throughout the pregnancy from fetal abdominal ultrasound. *American journal of obstetrics gynecology MFM*, 5(12), 101182.

Prabakaran, B. S., Hamelmann, P., Ostrowski, E., &Shafique, M. (2023). FPUS23: An Ultrasound Fetus Phantom Dataset with Deep Neural Network Evaluations for Fetus Orientations, Fetal Planes, and Anatomical Features. *IEEE Access*.

Qu, R., Xu, G., Ding, C., Jia, W., &Sun, M. (2020). Standard plane identification in fetal brain ultrasound scans using a differential convolutional neural network. *IEEE Access*, 8, 83821.

Rahmatullah, B., Papageorghiou, A., &Noble, J. A. (2011). *Automated selection of standardized planes from ultrasound volume*. Paper presented at the Machine Learning in Medical Imaging: Second International Workshop, MLMI 2011, Held in Conjunction with MICCAI 2011, Toronto, Canada, September 18, 2011. Proceedings 2.

- Rahmatullah, B., Papageorghiou, A. T., & Noble, J. A.** (2012). *Image analysis using machine learning: Anatomical landmarks detection in fetal ultrasound images*. Paper presented at the 2012 IEEE 36th Annual Computer Software and Applications Conference.
- Ravishankar, H., Prabhu, S. M., Vaidya, V., & Singhal, N.** (2016). *Hybrid approach for automatic segmentation of fetal abdomen from ultrasound images using deep learning*. Paper presented at the 2016 IEEE 13th international symposium on biomedical imaging (ISBI).
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A.** (2016). *You only look once: Unified, real-time object detection*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Roy, P., & Bilodeau, G.-A.** (2019). *Adversarially Learned Abnormal Trajectory Classifier*. Paper presented at the 2019 16th Conference on Computer and Robot Vision (CRV).
- Saha, S.** (2014). *Ultrasound Image Processing for CAD and Other Applications*. Indian Institute of Technology, Bombay Mumbai,
- Salomon, L. J., Alfirevic, Z., Berghella, V., Bilardo, C., Hernandez-Andrade, E., Johnsen, S., Kalache, K., Leung, K.-Y., Malinger, G., & Munoz, H.** (2011). Practice guidelines for performance of the routine mid-trimester fetal ultrasound scan. *Ultrasound in Obstetrics & Gynecology*, 37(1).
- Sari, H. Y., & Çiğdem, Z.** (2013). Gestasyon haftalarına göre bebeğin gelişimsel bakımının planlanması. *Dokuz Eylül Üniversitesi Hemşirelik Fakültesi Elektronik Dergisi*, 6(1), 40.
- Sherstinsky, A.** (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306.
- Shi, Y., Zeng, W., Huang, T., & Wang, Y.** (2015). *Learning deep trajectory descriptor for action recognition in videos using deep neural networks*. Paper presented at the 2015 IEEE international conference on multimedia and expo (ICME).
- Sinclair, M., Baumgartner, C. F., Matthew, J., Bai, W., Martinez, J. C., Li, Y., Smith, S., Knight, C. L., Kainz, B., & Hajnal, J.** (2018). *Human-level performance on automatic head biometrics in fetal ultrasound using fully convolutional neural networks*. Paper presented at the 2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC).

- Singh, D., Regatte, R. R., & Zibetti, M. V.** (2024). HDNLS: Hybrid Deep-Learning and Non-Linear Least Squares-Based Method for Fast Multi-Component T1 ρ Mapping in the Knee Joint. *Bioengineering*, 12(1), 8.
- Sobhaninia, Z., Rafiei, S., Emami, A., Karimi, N., Najarian, K., Samavi, S., & Sorousmehr, S. R.** (2019). *Fetal Ultrasound Image Segmentation for Measuring Biometric Parameters Using Multi-Task Deep Learning*. Paper presented at the 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC).
- Song, W., Li, L., & Ren, Z.** (2019). Ultrasonic image processing based on fusion super-resolution reconstruction of familiar models. *Journal of Visual Communication Image Representation*, 64, 102633.
- Soviany, P., & Ionescu, R. T.** (2018). *Optimizing the trade-off between single-stage and two-stage deep object detectors using image difficulty prediction*. Paper presented at the 2018 20th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC).
- Staudemeyer, R. C., & Morris, E. R.** (2019). Understanding LSTM--a tutorial into long short-term memory recurrent neural networks. *arXiv preprint arXiv:1905.09586*.
- Sundaresan, V., Bridge, C. P., Ioannou, C., & Noble, J. A.** (2017). *Automated characterization of the fetal heart in ultrasound images using fully convolutional neural networks*. Paper presented at the 2017 IEEE 14th international symposium on biomedical imaging (ISBI 2017).
- Surlea, C., Kurugollu, F., Milligan, P., & Ong, S.** (2011). *Foetal motion classification using optical flow displacement histograms*. Paper presented at the Proceedings of the 4th International Symposium on Applied Sciences in Biomedical and Communication Technologies.
- Tang, S., & Chen, S.-p.** (2009). A fast automatic recognition and location algorithm for fetal genital organs in ultrasound images. *Journal of Zhejiang University SCIENCE B*, 10, 648.
- Turkan, M., Dandil, E., Urfali, F. E., & Korkmaz, M.** (2025). FetalMovNet: A Novel Deep Learning Model Based on Attention Mechanism for Fetal Movement Classification in US. *IEEE Access*.

- Turkan, M., Urfalı, F. E., & Dandı, E.** (2023). Automatic Fetal Motion Detection from Trajectory of US Videos Based on YOLOv5 and LSTM. In *Explainable Machine Learning for Multimedia Based Healthcare Applications* (pp. 1): Springer.
- Turner, J. M., Cincotta, R., Chua, J., Gardener, G., Petersen, S., Thomas, J., Lee-Tannock, A., & Kumar, S.** (2023). Decreased fetal movements—the utility of ultrasound to identify infants at risk and prevent stillbirth is poor. *American journal of obstetrics gynecology MFM*, 5(2), 100782.
- Turner, J. M., Flenady, V., Ellwood, D., Coory, M., & Kumar, S.** (2021). Evaluation of pregnancy outcomes among women with decreased fetal movements. *JAMA network open*, 4(4), e215071.
- Türker, Ü.** (2023). *Motor Gelişim*.
- Tzutalin, D.** (2015). LabelImg. *GitHub repository*, 6, 4.
- UN.** (2020). Report of the UN Inter-agency Group for Child Mortality Estimation, 2020-A Neglected Tragedy The global burden of stillbirths. [Erişim Tarihi: 16.03.2025, <https://childmortality.org/wp-content/uploads/2020/10/UN-IGME-2020-Stillbirth-Report.pdf>].
- van den Heuvel, T. L., de Bruijn, D., de Korte, C. L., & Ginneken, B. v.** (2018). Automated measurement of fetal head circumference using 2D ultrasound images. *PloS one*, 13(8), e0200412.
- van den Heuvel, T. L., Petros, H., Santini, S., de Korte, C. L., & van Ginneken, B.** (2019). Automated fetal head detection and circumference estimation from free-hand ultrasound sweeps using deep learning in resource-limited countries. *Ultrasound in medicine biology*, 45(3), 773.
- van Merendonk, E. J., Brouwers, J. J., De Catte, L., Hasaerts, D., Nijhuis-van der Sanden, M. W., & Kerckhofs, E.** (2017). Identification of prenatal behavioral patterns of the gross motor movements within the early stages of fetal development. *Infant Child Development*, 26(5), e2012.
- van Sloun, R. J., Solomon, O., Bruce, M., Khaing, Z. Z., Wijkstra, H., Eldar, Y. C., & Mishi, M.** (2020). Super-resolution ultrasound localization microscopy through deep learning. *IEEE transactions on medical imaging*, 40(3), 829.

- Velazquez, M. D., &Rayburn, W. F.** (2002). Antenatal evaluation of the fetus using fetal movement monitoring. *Clinical obstetrics and gynecology*, 45(4), 993.
- Vosta, S., &Yow, K.-C.** (2023). KianNet: A violence detection model using an attention-based CNN-LSTM structure. *IEEE Access*.
- Wang, C.-Y., Liao, H.-Y. M., Wu, Y.-H., Chen, P.-Y., Hsieh, J.-W., &Yeh, I.-H.** (2020). *CSPNet: A new backbone that can enhance learning capability of CNN*. Paper presented at the Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops.
- Wang, J., Yang, Y., Mao, J., Huang, Z., Huang, C., &Xu, W.** (2016). *Cnn-rnn: A unified framework for multi-label image classification*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Wang, L., Qiao, Y., &Tang, X.** (2015). *Action recognition with trajectory-pooled deep-convolutional descriptors*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Wang, P., Li, Z., Hou, Y., &Li, W.** (2016). *Action recognition based on joint trajectory maps using convolutional neural networks*. Paper presented at the Proceedings of the 24th ACM international conference on Multimedia.
- Warrick, P., Hamilton, E., Kearney, R., &Precup, D.** (2010). *A machine learning approach to the detection of fetal hypoxia during labor and delivery*. Paper presented at the Proceedings of the AAAI Conference on Artificial Intelligence.
- Whitehead, C. L., Cohen, N., Visser, G. H., &Farine, D.** (2019). Are increased fetal movements always reassuring? *The Journal of Maternal-Fetal & Neonatal Medicine*, 1.
- WHO.** (2019). Trends in Maternal Mortality 2000 to 2017 Estimates by WHO, UNICEF, UNFPA, World Bank Group and the United Nations Population Division. [Erişim Tarihi: 16.03.2025, <https://iris.who.int/bitstream/handle/10665/327596/WHO-RHR-19.23-eng.pdf?sequence=13&isAllowed=y>].
- Williams, G., Baxter, R., He, H., Hawkins, S., &Gu, L.** (2002). *A comparative study of RNN for outlier detection in data mining*. Paper presented at the 2002 IEEE International Conference on Data Mining, 2002. Proceedings.

- Wróbel, J., Kupka, T., Horoba, K., Matonia, A., Roj, D., & Jeżewski, J.** (2014). Automated detection of fetal movements in Doppler ultrasound signals versus maternal perception. *Journal of Medical Informatics & Technologies*, 23.
- Wu, L., Cheng, J.-Z., Li, S., Lei, B., Wang, T., & Ni, D.** (2017). FUIQA: fetal ultrasound image quality assessment with deep convolutional networks. *IEEE transactions on cybernetics*, 47(5), 1336.
- Yang, T., Ren, P., Xie, X., & Zhang, L.** (2021). *Gan prior embedded network for blind face restoration in the wild*. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.
- Yaqub, M., Kelly, B., Papageorghiou, A. T., & Noble, J. A.** (2017). A deep learning solution for automatic fetal neurosonographic diagnostic plane verification using clinical standard constraints. *Ultrasound in medicine biology*, 43(12), 2925.
- Yaqub, M., Napolitano, R., Ioannou, C., Papageorghiou, A. T., & Noble, J. A.** (2012). *Automatic detection of local fetal brain structures in ultrasound images*. Paper presented at the 2012 9th IEEE International Symposium on Biomedical Imaging (ISBI).
- Yasrab, R., Zhao, H., Fu, Z., Drukker, L., Papageorghiou, A. T., & Noble, J. A.** (2024). Automating the Human Action of First-Trimester Biometry Measurement from Real-World Freehand Ultrasound. *Ultrasound in medicine biology*, 50(6), 805.
- You, J., Li, Q., Guo, Z., & Zhao, R.** (2017). *Smart fetal monitoring*. Paper presented at the International Conference on Information Science and Applications.
- Yu, Z., Tan, E.-L., Ni, D., Qin, J., Chen, S., Li, S., Lei, B., & Wang, T.** (2017). A deep convolutional neural network-based framework for automatic fetal facial standard plane recognition. *IEEE journal of biomedical health informatics*, 22(3), 874.
- Zhang, B., Liu, H., Luo, H., & Li, K.** (2021). Automatic quality assessment for 2D fetal sonographic standard plane based on multitask learning. *Medicine*, 100(4), e24427.
- Zhang, J., & Liu, Z.** (2008). *Detecting abnormal motion of pedestrian in video*. Paper presented at the 2008 International Conference on Information and Automation.
- Zhang, J., & Liu, Z. J.** (2023). Abnormal behavior of pedestrian detection based on fuzzy theory. *Moshi Shibie yu Rengong Zhineng/Pattern Recognition and Artificial Intelligence*, 23, 421.