

T.C.
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**OBJEKTİF AĞRI DEĞERLENDİRMESİ İÇİN ÇOK BOYUTLU BİYOSİNYAL
FÜZYONU**

YÜKSEK LİSANS TEZİ

ELİF YILDIRIM

2100007471

Anabilim Dalı: Bilgisayar Mühendisliği

Program: Bilgisayar Mühendisliği

Tez Danışmanı: Doç. Dr. Fatma Patlar Akbulut

HAZİRAN 2024

T.C.
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

OBJEKTİF AĞRI DEĞERLENDİRMESİ İÇİN ÇOK BOYUTLU BİYOSİNYAL
FÜZYONU

YÜKSEK LİSANS TEZİ

ELİF YILDIRIM

2100007471

Anabilim Dalı: Bilgisayar Mühendisliği

Program: Bilgisayar Mühendisliği

Tez Danışmanı: Doç. Dr. Fatma Patlar Akbulut

Jüri Üyeleri:

Dr.Öğr.Üyesi Öznur Şengel

Doç.Dr. Can Eyüpoğlu

HAZİRAN 2024

TEŞEKKÜR

Bu zorlu yolculukta beni her zaman destekleyen ve bilime olan şevkimi arttıran danışman hocam Doç. Dr. Fatma Patlar Akbulut'a, Cerrahpaşa Hastanesi'nde veri toplamama imkân sağlayan Prof. Dr. Ela Tarakcı hocama, hastanede veri toplarken desteklerini esirgemeyen Dr. Öğr. Üyesi Eylül Pınar Kısa ve Dr. Öğr. Üyesi Gökçe Leblebici hocalarıma ve akademik yolculuğumda yanımda olan bütün hocalarıma ve çalışma arkadaşlarıma teşekkürlerimi sunuyorum.

Aileme; her zaman daha fazla çalışmam, okumam, üretmem konusunda arkamda oldukları için teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
TABLO LİSTESİ.....	v
ŞEKİL LİSTESİ.....	vii
KISALTMALAR VE TERİMLER.....	viii
ÖZET.....	ix
ABSTRACT.....	x
1. GİRİŞ.....	1
2. TEMEL KAVRAMLAR	3
2.1. Ağrı Tanımı ve Çeşitleri.....	3
2.2. Ağrı Ölçekleri.....	3
2.2.1. Visual Analog Scale (VAS).....	4
2.2.2. Numeric Rating Scale (NRS-11)	4
2.2.3. Verbal Rating Scale (VRS).....	5
2.2.4. Faces Pain Scale(FPS)	5
2.2.5. McGill Pain Questionnaire	6
2.3. Romatolojik Hastalıklar ve Ağrı	6
2.3.1. Çocukluk Çağı Romatoloji Hastalıkları.....	7
2.4. Literatürde Yapay Zeka ile Ağrı Analizi Konusunda Yapılmış Çalışmalar.....	8
2.4.1. Ağrı ile İlgili Toplanmış Verisetleri	8
2.4.2. Yapay Zeka ile Ağrı Tanıma Teknikleri.....	9
2.5.Biyosinyal ile Çalışan Derin Öğrenme Mimarileri	11
2.5.1.LSTM	11

2.5.2.Dönüştürücü (Transformer).....	12
2.5.3. Dikkat (Attention)	13
2.5.4.Multi-Head Attention	15
3. YÖNTEM	16
3.1. Veri Toplama Protokolü.....	17
3.1.1.Ağrı Ölçeği	18
3.1.2.Sinyal Verisi	18
3.2.Verinin Önışlenmesi.....	20
3.2.1.Sinyallerin Yeniden Örneklenmesi	20
3.2.2. Verilerin Etiketlenmesi.....	20
3.3. RheumaPain Veriseti	21
3.3.1. Popölasyon	22
3.3.2. Ağrı Seviyelerinin Dağılımı	24
3.4.Çoklu Ağrı Veriseti	25
3.5. Verisetlerindeki Ağrı Ölçeklerinin Eşit Temsili	25
3.6. Ağrı Seviyesi Tahmini için Geliştirilen Derin Öğrenme Modelleri.....	26
3.6.1. LSTM ve Multi-Head Attention Modeli	26
3.6.2. 1D-CNN Modeli.....	27
3.6.3. Dönüştürücü(Transformer) Modeli	28
4. DENEYSEL SONUÇLAR	30
4.1. Ağrı Seviyesi Tespiti Sonuçları.....	30
4.1.1.Derin Öğrenme Modellerinin RheumaPain Veriseti ile Eğitilmesi.....	30
4.1.2. Derin Öğrenme Modellerinin Ağrı Füzyonu Veriseti ile Eğitilmesi.....	32
5. TARTIŞMA	39
6. SONUÇ.....	42

7. KAYNAKÇA.....	44
------------------	----



TABLO LİSTESİ

Tablo 1: Sinyal verilerinin yeniden örneklenmesi	20
Tablo 2: RheumaPain Verisetindeki özellikler, veri tipleri ve açıklamaları	22
Tablo 3: Çoklu Ağrı Veriseti özellikleri	25
Tablo 4: Dönüştürücü (Transformers) Modelinin farklı frekans değerlerine sahip RheumaPain Verisetleri ile Eğitilmesi.....	30
Tablo 5: 1D-CNN'in RheumaPainScaled'in farklı frekanslardaki verisetleri ile eğitildiğinde ortaya çıkan sonuçlar	31
Tablo 6-LSTM ve Attention Modelinin farklı Hz verilerine sahip RheumaPain Veriseti ile eğitiminden elde edilen sonuçlar.....	31
Tablo 7: 1D-CNN Ağrı Füzyonu Veriseti ile ağrı seviyesi tespiti için eğitilmesi sonucu çıkan doğruluk, kayıp ve F1-Skoru değerleri.....	32
Tablo 8: Transformer Ağrı Füzyonu Veriseti ile ağrı seviyesi tespiti için eğitilmesi sonucu çıkan doğruluk, kayıp ve f1 skoru değerleri.....	32
Tablo 9: LSTM ve Multi-Head Attention modelinin iki verisetinin birleştirilmesi ile oluşan Ağrı Füzyonu Veriseti ile eğitilmesi ve çıkan sonuçlar.....	33
Tablo 10: 1D-CNN Modelinin Çoklu Ağrı Veriseti ile eğitilmesi sonucu elde edilen değerler.....	33
Tablo 11: Önceden eğitilmiş 1D-CNN modelinin RheumaPain ile eğitilmesi.....	34
Tablo 12: Transformer modelinin Çoklu Ağrı Veriseti ile önceden eğitimi.....	34
Tablo 13: Transformer Modelinin katmanları dondurularak model RheumaPain ile eğitildiğinde elde edilen sonuçlar.....	35
Tablo 14: LSTM ve Dikkat(Attention) Modelinin Çoklu Ağrı Veriseti ile önceden eğitilmesi sonucu elde edilen bulgular.....	35
Tablo 15: Önceden eğitilmiş LSTM ve Dikkat modelinin RheumaPain ile yeniden eğitimi	36
Tablo 16: 1D-CNN modelinin ağrı tespiti için PainFusion Veriseti ile eğitilmesi	36
Tablo 17: Dönüştürücü (Transformer) modelinin ağrı tespiti için PainFusion Veriseti ile eğitilmesi.....	37

Tablo 18: LSTM ve Dikkat(Attention) modelinin ağrı tespiti için PainFusion Veriseti ile eğitilmesi.....	37
Tablo 19: 1D-CNN, Transformer ve Dense yapısını içeren modelin ağrı tespiti için PainFusion ile eğitimi sonucu elde edilen değerler.....	38
Tablo 20: Bu çalışmanın literatürdeki diğer çalışmalarla ağrı şiddeti tespiti bağlamında kıyaslanması.....	41



ŞEKİL LİSTESİ

Şekil 1: VAS Ağrı Ölçeği (Kaynak: [9]).	4
Şekil 2: Numerik Ağrı Ölçeği (Kaynak: [11]).	5
Şekil 3: Wong-Baker Yüzler Ağrı Ölçeği (Kaynak: [16]).	5
Şekil 4: McGill Ağrı Ölçeği (Kaynak: [17, Melzack]).	6
Şekil 5: LSTM Mimarisi ve Çalışma Mekanizması (Kaynak: [36]).	12
Şekil 6: Dönüştürücü (Transformer) Mimarisi (Kaynak: [33]).	13
Şekil 7: Dikkat(Attention)'in çalışma mekanizması (Kaynak: [38]).	14
Şekil 8: Multi-Head Attention Mimarisi (Kaynak: [33]).	15
Şekil 9: İzlenen yöntemin kısa özeti	17
Şekil 10: Cerrahpaşa Çocuk Acil Fizyoterapi ve Rehabilitasyon Bölümü'nde tedavi olan bir hasta	18
Şekil 11: Cinsiyet: Kadın, Yaş: 17, Hastalık Tanı: JIA, Ağrı Seviyesi(Egzersiz): 4, Ağrı Seviyesi(İstirahat): 0.	19
Şekil 12: Cinsiyet: Kadın, Yaş: 18, Tanı: JIA, Ağrı Seviyesi(egzersiz): 4, Ağrı Seviyesi(istirahat): 3.	21
Şekil 13: a) Hastaların yaş dağılımları, b)Cinsiyete göre yaş dağılımları, c) Tanı dağılımları, d) Cinsiyete göre tanı dağılımları	23
Şekil 14: Çocuk romatoloji hastalıklarının dört ana grubu ve alt grupları.	24
Şekil 15: 8 Hz'lik sinyal verisinde ağrı seviyeleri için toplanmış örnekler	24
Şekil 16: Multi-Head Attention ve LSTM Modeli.	27
Şekil 17: 1 Boyutlu Evrişimsel Sinir Ağı Modeli	28
Şekil 18: Dönüştürücü (Transformer) Modeli.	29

KISALTMALAR VE TERİMLER

Accuracy: Doğruluk

Loss: Kayıp

ACC: Accelerometer

EDA: Elektrodermal Aktivite

Temp: Vücut Sıcaklığı (Celcius)

Dense: Yapay sinir ağı

LSTM: Uzun Kısa Süreli Bellek

BVP: Kan basıncı (Blood Volume Pulse)

PPG: Fotopletismografi

Üniversite : T.C. İstanbul Kültür Üniversitesi

Enstitü : Lisansüstü Eğitim Enstitüsü

Anabilim Dalı : Bilgisayar Mühendisliği

Program : Bilgisayar Mühendisliği

Tez Danışmanı : Doç. Dr. Fatma Patlar AKBULUT

Tez Türü ve Tarihi : Yüksek Lisans – Haziran 2024

ÖZET

Ağrı, tanımlanması karmaşık olan ve kişiye göre farklılık gösterebilen bir durumdur, ancak fizyolojik sinyaller yardımı ile ağrı ile gösterilen reaksiyonlar arasında bir bağ kurmak mümkündür. Ağrı, çeşitli hastalıkların ilk habercisidir. Romatolojik hastalıklar da ağrı ile yakından ilişkili ve tedavi edilmezse ilerleyip insanın yaşam kalitesini düşüren bir hastalık grubudur. Özellikle gelişim çağındaki çocuklarda romatolojik hastalıkların erken teşhisi bu açıdan son derece önemlidir. Bu bilgiler ışığında çocuk romatoloji hastalarında ağrı tespiti yapılabilmesi fikri öne sürülmüş ve bu doğrultuda geliştirilen derin öğrenme modelleri ile bu fikir hayata geçirilmiştir. Cerrahpaşa Hastanesi Çocuk Acil Fizyoterapi ve Rehabilitasyon Bölümü'ndeki çocuk romatoloji hastalarından tedavi esnasında toplanan çok modlu biyosinyal verileri, hastalardan alınan geribildirimler ile çeşitli ağrı seviyelerini temsil edecek şekilde etiketlenmiş ve RheumaPain isimli ağrı veriseti oluşturulmuştur. Daha sonra bu veriseti, Çoklu Ağrı Veriseti isimli, farklı ağrı türlerini ve şiddetlerini içeren bir başka veriseti ile zenginleştirilmiş ve çeşitli derin öğrenme modelleri, ağrının türü ve şiddetini tespit etmek üzere eğitilmiştir. Sonuç olarak, %92 F1-Skoru ile ağrı seviyelerinin tespiti ve %79 F1-Skoru ile çeşitli ağrı türlerinin tespiti gerçekleştirilmiştir.

University : T.C. İstanbul Kültür University

Institute : Institute of Graduate Studies

Department : Computer Engineering

Program : Computer Engineering

Thesis Advisor : Assoc. Prof. Fatma Patlar AKBULUT

Degree Awarded And Date : MA –June 2024

ABSTRACT

Pain is a complex condition that varies from person to person, but it is possible to establish a connection between the reactions shown to pain and physiological signals. Pain is often the first indicator of various diseases. Rheumatological diseases, in particular, are closely related to pain and can significantly reduce a person's quality of life if left untreated. Early diagnosis of rheumatological diseases in children, especially those in their developmental stages, is crucial in this regard. Based on this information, the idea of detecting pain in pediatric rheumatology patients has been proposed, and deep learning models have been developed to bring this idea to life. Multimodal biosignal data collected from pediatric rheumatology patients at the Cerrahpaşa Hospital Pediatric Emergency Physiotherapy and Rehabilitation Department during treatment were labeled to represent various pain levels based on feedback from the patients, resulting in the creation of the RheumaPain dataset. This dataset was later enriched with another dataset named the Multi-Pain Dataset, which includes different types and intensities of pain. Various deep learning models were trained to detect the type and intensity of pain. As a result, pain levels were detected with a 92% F1-Score, and various pain types were detected with a 79% F1-Score.

1. GİRİŞ

Ağrı, ortada duygusal veya fiziksel bir zarar ya da rahatsızlık olduğunda, sinir uçlarının bu sinyalleri beyne iletmesi sonucu ortaya çıkan durumdur [1]. Her insan ağrıyla farklı şekilde ve farklı şiddette deneyimleyebilir. Ağrıyı tanımak ve analiz etmek ağrının doğası gereği her insanda farklı gözlemlenmesi ele alındığında büyük bir problemdir. Bunun nedeni; fizyolojik farklılıklar, psikolojik faktörler, kültürel etkiler ve daha birçok etkenin kombinasyonu olarak sıralanabilir. Bu durum, ağrının subjektif bir deneyim olmasını sağlar. Bunun yanında ağrı, farklı alt başlıklara ayrılmaktadır. Ağrıyı kısaca akut ve kronik olmak üzere iki ana başlıkta tanımlamak mümkündür. Akut ağrı geçici olup kronik ağrı 6 ay ya da daha uzun süren bir ağrıyı ifade etmek için kullanılmaktadır. Ağrıyı tanımlarken öne çıkan bir diğer nokta, farklı diller arasındaki anlam karmaşasıdır. İngilizce'deki 'pain' kelimesi hem acı, hem ağrıyı tanımlamak için kullanılır ve dışarıdan aktarılan bir acıya gösterilen tepki de 'pain' olarak adlandırılır. Subjektif doğasına ve çok boyutlu anlamına rağmen ağrıyı objektif olarak gözlemlemek imkânsız değildir. Terleme, nabız yükselmesi ve vücut sıcaklığının artması gibi fizyolojik tepkiler, ya da yüz ifadeleri, ağrının varlığının tespitinde aydınlatıcı bir etkiye sahiptir. Bu konuda, objektif ağrı değerlendirmesine ışık tutması açısından çeşitli verisetleri oluşturulmuştur. Bazılarında [2, 3, 4] dışarıdan aktarılan acıdan yararlanılmaktadır. Bazılarında ise devam eden bir hastalıktan [5, 6, 7] ya da ameliyat sonrası hastalardan [8] alınan ağrı verileri kullanılmaktadır.

Ağrının varlığının bilinmesi, birçok hastalığın erken teşhis ve tedavisi açısından kritik öneme sahiptir. Ağrısını ifade edebilen yetişkin insanlarda hastalıklara daha erken müdahale edilebilirken bebek, çocuk, yaşlı, koma hastaları, felçli hastalar ve kendini ifade edemeyen diğer hastalara tedavi geç ulaşmakta ve hastalıkların seyri ilerleyerek geri dönülemez noktalara gelebilmektedir. Buna dahil olan önemli bir hastalık grubunu romatolojik hastalıklar oluşturmaktadır. Çünkü ağrı, birçok romatolojik hastalığın ana habercisidir [9]. Romatolojik hastalık teşhisi almış kişiler ağırlıklı olarak yoğun kas ve eklem ağrılarından şikayetçi olmaktadır ve hareketsiz kaldıkları müddetçe hastalığın tedavi süreci aksamakta, bunun yanında hastalar daha şiddetli ağrılar ile mücadele etmek zorunda kalmaktadır. Bunun için, ağrının dışarıdan gözlemlenebilmesi ve zamanında müdahale edilebilmesi için bir sistem kurulması ihtiyacı doğmuştur.

Yapay zekâ, günümüzde birçok alanda olduğu gibi sağlık alanında da kullanımı giderek yaygınlaşmakta ve geliştirilmekte olan bir konudur. Yapay zekâ yardımı ile fizyolojik sinyaller ve insanların ifade ettikleri ağrı şiddeti birleştirilerek ağrının çeşidini ve şiddetini tahmin eden modellemeler yapılması imkân dahilindedir. Bu doğrultuda, romatoloji hastalarında ağrının objektif analizinde kullanılmak üzere çocuk romatoloji hastalarının ağrı seviyelerini içeren bir zaman serisi sinyal veriseti olan RheumaPain Veriseti oluşturulmuştur. Veriler, Cerrahpaşa Hastanesi Çocuk Acil Bölümü'ndeki çocuk romatoloji hastalarının tedavi esnasında E4 Empatica giyilebilir cihazı ile alınan çok modlu fizyolojik sinyalleri ve hastaların Wong-Baker Yüzler Ağrı Ölçeği isimli ağrı ölçeğinde belirttikleri ağrı seviyelerini içermektedir. Geliştirilmiş olan derin öğrenme modelleri tarafından romatoloji hastası çocukların ağrı seviyeleri analiz edilmiş ve modelin güvenilirliği test edilmiştir. Bunun yanında üç ayrı ağrı türünü içeren başka bir veriseti olan Çoklu Ağrı Veriseti ile modeller zenginleştirilmiş ve doğruluk oranları arttırılmıştır. Ayrıca, romatolojik ağrının yanı sıra baş ağrısı, sırt ağrısı, adet ağrısı gibi çeşitli ağrı türlerini sınıflandıran derin öğrenme modelleri oluşturulmuş ve doğrulukları test edilmiştir.

Özetle; bu çalışmanın amacı, oluşturulan yapay zekâ modellerinin ağrı konusunda kapsamlı bir analiz yapabilmesi ve gelecekteki çalışmalarda ağrısını ifade edemeyen bireylerin fizyolojik sinyallerini gözlemleyerek deneyimlenen ağrının şiddetini ve türünü tespit edebilmesidir.

Bu çalışmanın literatüre katkıları:

- Fizyolojik sinyaller ve etiketlenen ağrı şiddeti arasındaki bağlantı tespit edilmiştir.
- Çok modlu fizyolojik sinyal verisi ile ağrının yoğunluğunu tahmin edebilen derin öğrenme model geliştirilmiş ve %91,33 oranında başarılı sonuçlar alınmıştır.
- Çok modlu fizyolojik sinyal verisi ile ağrının türü %79 F1-skoru ile başarı ile tespit edilebilmektedir.
- Kendisini ifade edemeyen hastalarda ağrı tespiti yapılabilmesi için altyapı sağlanmıştır.

2. TEMEL KAVRAMLAR

2.1.Ağrı Tanımı ve Çeşitleri

İngilizcede ağrı ve acıyı ifade etmek için aynı kelime (“pain”) kullanılır. Türkçede bu durum karmaşa yaratabilmektedir. Bunun için ağrının tıp literatüründe nasıl tanımlandığı ve çeşitlerinin neler olduğunu bilmek bu çalışma için önem taşımaktadır. Literatürde ağrının güncel tanımı “Gerçek veya potansiyel doku hasarıyla ilişkili veya buna benzeyen hoş olmayan duyuşsal ve duygusal deneyim” [1] olarak geçmektedir. Ağrı; deneyimlendiği bölge, nedeni, sıklığı, yoğunluğu ve süresi ele alınarak sınıflandırılır [10].

- Zaman söz konusu olduğunda ağrıyı akut ve kronik olmak üzere iki ayrı çeşitte sınıflandırabiliriz. Akut ağrı genellikle 1 aydan kısa süren ağrıdır. Sub-akut ağrı ise 1-6 ay kadar sürer. Kronik ağrı 6 aydan uzun sürer.
- Mekanik olarak nöropatik ve nosiseptif olarak sınıflandırılır. Nöropatik ağrı, sinirlerin doğrudan zarar görmesi sonucu ortaya çıkar. Nosiseptif ağrı ise doku zedelenmesinden kaynaklanır ve amacı vücudu zarardan korumaktır.
- Tıbbi teşhisler açısından; hayalet ağrı, kanser ağrısı, vasküler ağrı, artirik ağrı, damar ağrısı, kas ağrısı, fibromiyalji, miyofasiyal ağrı, vb. çeşitleri vardır.
- Anatomik olarak ağrı, vücudun hangi bölgelerinde hissedildiğine göre farklı isimler almaktadır (Örnek: Baş ağrısı).

2.2.Ağrı Ölçekleri

İnsanların deneyimlediği ağrı hakkında bilgi sahibi olmak için şimdiye kadar farklı ağrı ölçekleri kullanılmıştır. Bu ölçeklerin puanlanması sayesinde birinin ağrısının yoğunluğunun ve hissettirdiklerinin başka biri ya da tedavi eden kişi tarafından anlaşılması kolaylaşmıştır. Ağrı ölçeği deneyin yapılacağı grup için büyük öneme sahiptir. Bazı ağrı ölçeklerinde çocuklar kendilerini daha iyi ifade edebilirken bazıları yetişkinler için daha kapsamlı ve detaylı sonuçlara ulaşılmasını sağlamaktadır. Yaşlılar için de daha iyi sonuç verebilen ağrı ölçekleri kullanılmaktadır.

2.2.1. Visual Analog Scale (VAS)

En yaygın kullanılan ağrı ölçeklerinden biridir. VAS ölçeğinde [11] ağrıyı deneyimleyen hastadan “Hiç Ağrı Yok” ifadesinden başlayıp “Çok Şiddetli Ağrı” ifadesine kadar uzanan 100 mm’lik bir doğru üzerine bir çizgi çizerek ağrısının o anki durumunu ifade etmesi istenir. VAS’ın amacı ağrı gibi belirsiz ve değişken bir durumda hastaların ayırık, sıçrayan değerler yerine süreklilik içeren değerler arasından ağrısının seviyesini ölçek üzerinde işaretleyerek belirtmesidir.

No pain | _____ | Very severe pain

Şekil 1: VAS Ağrı Ölçeği (Kaynak: [11]).


VAS’ın güvenilirliği ve geçerliliği hakkında yapılmış bir çalışmada [12] VAS’ın uluslararası alanda yaygın kullanımda olduğu, bilimsel olarak VAS’ın 18 yaş üstü katılımcılar için güvenilir ve geçerli bir ölçek olduğu tespit edilmiştir. Farklı kültürlerden, farklı dili konuşan insanlar VAS’ı kullanırken problem yaşamamaktadır.

2.2.2. Numeric Rating Scale (NRS-11)

NRS, hastaların veya ağrı deneyimleyen kişilerin ağrı seviyelerini ölçekte görülen 0-10 arasındaki numaralar üzerinden tanımlamasını sağlar. NRS’ye göre ağrı seviyeleri:

- 0:hiç ağrı yok,
- 1-3: hafif ağrı,
- 4-6: orta seviyede ağrı ve
- 7-10: şiddetli ağrı

olarak sınıflandırılır. Bu ölçeğin VAS üzerindeki avantajı, hem telefon üzerinden sesli olarak, hem de yazı üzerinden cevabın iletebilmesidir [13]. VAS gibi NRS de farklı dil ve kültürlerle mensup insanlar tarafından kullanılabilir. Çocuk hastalarda ise NRS’nin yaygın olarak sekiz yaş üstü çocuklarda kullanıldığı gözlemlenmiştir [14]. Daha küçük yaştaki çocuklar ise her ne kadar sayı saymayı biliyor olsalar da kendilerini sayılarla ifade etme ve ağrı ile sayılar arasında bir ilişki kurma konusunda yeterli algıya sahip olmadıkları için güvenilir rakamlar verebilirler.



Şekil 2: Numerik Ağrı Ölçeği (Kaynak: [15]).

2.2.3. Verbal Rating Scale (VRS)

VRS’de hastalar deneyimledikleri ağrı şiddetini sözel olarak ifade eder. Uzunluğu genellikle 4-7 kategori arasında değişmekte olup altı kategorili bir VRS kullanıldığında ölçek, “ağrı yok”, “hafif ağrı”, “ortalama ağrı”, “şiddetli ağrı”, “aşırı ağrı”, “hayal edilebilecek en yoğun ağrı” şeklinde kategorilere ayrılmakta ve hastadan birini seçmesi istenmektedir [16] ve VRS’nin düşük eğitim seviyesindeki ve yaşlı hastalar tarafından ağırlıklı olarak tercih edildiği gözlemlenmiştir.

2.2.4. Faces Pain Scale(FPS)

Faces Pain Scale [17], çocukların ağrı yoğunluğunu değerlendirmek için kullanılan bir ölçektir. Farklı FPS versiyonları olmakla birlikte bu ölçeğin ana fikri, sayılar ve kelimeler bazı küçük yaş grubundaki çocuklara karmaşık geleceğinden, görselleri kullanarak küçük yaştaki çocukların kendini ifade edebilmesine imkan sağlamaktır. Bunun için gülümseyen yüz ifadesinden ağlayan yüz ifadesine kadar giden, genellikle altı ya da beş yüzden oluşan bir skala kullanılır. Yüzlerin sayısı veya çizim tarzı farklı versiyonlarda değişiklik göstermektedir. Aşağıdaki ölçek FPS’nin bir versiyonu olan Wong-Baker Faces Pain Scale’in orijinal web sitesinden alınmıştır ve yüzleri, sayıları ve sözlü ifadeleri bir arada içermektedir. Wong-Baker Ağrı Değerlendirme Ölçeği günümüzde dünya çapında üç yaş ve üzeri çocuklar üzerinde kullanılmaktadır [18].



Şekil 3: Wong-Baker Yüzler Ağrı Ölçeği (Kaynak: [18]).

2.2.5. McGill Pain Questionnaire

McGill Ağrı Anketinin [19] geliştirilmesinin amacı, ağrıyı tanımlama ve ölçme problemine yeni bir bakış açısı getirmektir. Buna göre ağrıyı tanımlayan kelimeler bir araya getirilmiş ve kategorilere ayrılmıştır. Bu ölçek bize dilde ağrı deneyimini ve ağrının çeşitlerini tanımlamak için çok fazla kelime olduğunu, kelimelerin farklı ağrı tiplerini temsil eden sınıflara ayrıldığını ve kelimelerin insanlar için yaklaşık olarak aynı göreceli konumlara sahip olduğunu göstermektedir.

McGILL PAIN QUESTIONNAIRE
RONALD MELZACK

Patient's Name _____ Date _____ Time _____ am/pm

PRI: S _____ A _____ E _____ M _____ PRI(T) _____ PPI _____
(1-10) (11-15) (16) (17-20) (1-20)

1 FLICKERING	11 TIRING	BRIEF	RHYTHMIC	CONTINUOUS
2 QUIVERING	12 EXHAUSTING	MOMENTARY	PERIODIC	STEADY
3 PULSING	13 SICKENING	TRANSIENT	INTERMITTENT	CONSTANT
4 THROBBING	14 SUFFOCATING			
5 BEATING	15 FEARFUL			
6 POUNDING	16 FRIGHTFUL			
7 JUMPING	17 TERRIFYING			
8 FLASHING	18 PUNISHING			
9 SHOOTING	19 GRUELLING			
10 PRICKING	20 CRUEL			
11 BORING	21 VICIOUS			
12 DRILLING	22 KILLING			
13 STABBING	23 WRETCHED			
14 LANCINATING	24 BLINDING			
15 SHARP	25 ANNOYING			
16 CUTTING	26 TROUBLESOME			
17 LACERATING	27 MISERABLE			
18 PINCHING	28 INTENSE			
19 PRESSING	29 UNBEARABLE			
20 GNAWING	30 SPREADING			
21 CRAMPING	31 RADIATING			
22 CRUSHING	32 PENETRATING			
23 TUGGING	33 PIERCING			
24 PULLING	34 TIGHT			
25 WRENCHING	35 NUMB			
26 HOT	36 DRAWING			
27 BURNING	37 SQUEEZING			
28 SCALDING	38 TEARING			
29 SEARING	39 COOL			
30 TINGLING	40 COLD			
31 ITCHY	41 FREEZING			
32 SMARTING	42 NAGGING			
33 STINGING	43 NAUSEATING			
34 DULL	44 AGONIZING			
35 SORE	45 DREADFUL			
36 HURTING	46 TORTURING			
37 ACHING	47 PPI			
38 HEAVY	48 NO PAIN			
39 TENDER	49 MILD			
40 TAUT	50 DISCOMFORTING			
41 RASPING	51 DISTRESSING			
42 SPLITTING	52 HORRIBLE			
	53 EXCRUCIATING			

E = EXTERNAL
I = INTERNAL

COMMENTS:

© R. MELZACK, 1975

Şekil 4: McGill Ağrı Ölçeği (Kaynak: [20, Melzack]).

2.3. Romatolojik Hastalıklar ve Ağrı

Romatolojik hastalıklar; kasları, kemikleri, eklemleri ve bağ dokularını etkileyen çeşitli hastalıkları kapsayan bir hastalık grubudur. Birçok romatolojik hastalık, bağışıklık sisteminin yanlışlıkla vücuttaki dokulara saldırması, ve bu durumun ağrı, iltihap veya doku hasarı gibi belirtilerle kendini göstermesiyle anlaşılmaktadır. Teşhis gecikmesi

romatoloji hastalıklarının en büyük sorunlarından biridir [21]. Erken tanı, romatoid artrit (RA), sistemik lupus eritematozus (SLE), myozit, primer Sjögren sendromu (SS) ve sistemik skleroz (SSc) gibi hastalıklarda iyileştirilmiş hastalık sonuçları ve tedavi stratejisi seçimi için kritik öneme sahiptir [22]. Özellikle çocuklarda hastalıkların teşhisi ne kadar erken konulursa o kadar erken sonuç alınabileceği için romatolojik hastalığa sahip çocukların da ağrısını ifade edebilmesi, veya ifade edemedikleri yerlerde ağrının dışarıdan anlaşılabilmesi önemli bir noktadır.

2.3.1. Çocukluk Çağı Romatoloji Hastalıkları

Çocuklarda romatoloji hastalıkları dört ana başlıkta görülmektedir. Bunlar; Juvenile idiopathic arthritis(JIA), Juvenile dermatomyositis, Systemic lupus erythematosus ve Juvenile scleroderma'dır.

Juvenile idiopathic arthritis(JIA): Çocuklarda en sık görülen kronik romatizmal hastalık olup nedeni bilinmemektedir [23]. Hastalığın ana kriterleri, hastalığın 16 yaşından önce başlaması, en az bir eklemden artrit 6 haftadan uzun süre devam etmesi ve eklem iltihabının diğer olası nedenlerinin dışlanmasıdır. Eklemlerdeki kronik iltihaplanma, hastanın günlük yaşamdaki fonksiyonel yeteneğini ve üretkenliğini belirgin şekilde sınırlar. Bunun nedeni kontrol altına alınmayan inflamasyondur. Tedavi edilmeyen hastalarda eklem komplikasyonları dışında büyüme geriliği, üveit, körlük ve hayatı tehdit eden MAS gibi birçok komplikasyon gelişebilmektedir. Bu nedenle JIA tedavisi hızlı ve etkili olmalıdır. Terapinin amacı çok boyutlu olmalıdır: ağrıyı kontrol etmek, hareket açıklığını/kas gücünü/kas fonksiyonunu korumak, hastalığın remisyonunu sağlamak, sistemik komplikasyonları yönetmek ve normal fiziksel ve psikososyal gelişimi kolaylaştırmak.

Juvenile dermatomyositis (JDM): Çocukluk döneminde başlayan nadir, sıklıkla kronik bir otoimmün hastalıktır. Proksimal kaslarda zayıflık ve patognomonik deri döküntüleri ile karakterizedir [24]. JDM'nin görülme sıklığı 16 yaşın altındaki 1 milyon çocukta yaklaşık 1,9'dur [25]. JDM'den etkilenen çocukların çoğunda kronik hastalık olacaktır ve uzun süreli tedavi gerektirecektir. Erken tanı ve immünsüpresif tedavi hastalığın seyri hakkındaki öngörülerini iyileştirmiştir.

Systemic Lupus Erythematosus(SLE): Bu hastalığa hem yetişkinlerde hem çocuk ve ergenlerde rastlanmaktadır. SLE'nin klinik görünümü ve hastalık seyri değişkendir ve nispeten hafif hastalıktan ciddi organ ve/veya yaşamı tehdit eden hastalığa kadar bir spektrumu kapsar [26]. Hastalığın ciddiyeti ve sonuçları dikkate alındığında başlangıç yaşı önemlidir. Çocukluk veya ergenlik döneminde ortaya çıktığında, SLE daha şiddetli hastalık seyri, daha yüksek hastalık aktivitesi ve artan majör organ tutulumu riski ile ilişkilidir.

Juvenil Skleroderma(JSkl): Organ fibrozisi ile karakterize edilen ve 16 yaşından önce başlayan bir dizi bozukluğu temsil eder [27]. Bu durumların etiyolojisi hakkında çok az şey bilinmektedir, ancak genetik ve çevresel faktörlerin bir kombinasyonunun, inflamasyonu, otoimmüniteyi, vaskülopatiyi ve ilerleyici fibro-proliferatif değişiklikleri içeren karmaşık bir patojenik zinciri başlatabileceğine inanılmaktadır.

2.4.Literatürde Yapay Zeka ile Ağrı Analizi Konusunda Yapılmış Çalışmalar

2.4.1. Ağrı ile İlgili Toplanmış Verisetleri

Ağrıyı gözlemlemek ve analiz etmek için çeşitli verisetleri oluşturulmuştur ve bu verisetleri farklı disiplinlerdeki çalışmaların yanı sıra bilgisayar bilimlerinde ve yapay zekada da ağrı tanıma çalışmalarında kullanılmıştır.

Bu konuda oluşturulmuş en popüler verisetlerinden biri EmoPain [5] verisetidir. Bu verisetinin içeriğinde etiketlenmiş yüksek çözünürlüklü ve farklı açılardan çekilmiş yüz videoları, odada kaydedilmiş ses sinyalleri, üç boyutlu vücut hareketleri kayıtları ve elektromiyografik sinyaller (EMG) yer alır. Bu veriler, kronik bel ağrısı çeken 22 kişiden ve kronik bel ağrısı geçmişi olmayan 28 kişiden oluşan iki ayrı grubun evlerinde yaptıkları egzersizler sırasında kaydedilmiştir.

BioVid [2] de bu konuda popüler olan bir başka verisetidir. BioVid veriseti, 37 sağlıklı gönüllünün, termal bir ızgaradan yüksek ısı verilerek uyarıldıklarında deneyimledikleri acı esnasında kaydedilen biyosinyallerini içerir. BioVid'in içerisinde görseller ve Biopotentials adı verilen çeşitli sinyaller yer almaktadır. Biopotential sinyalleri EMG, SCL, ECG ve EEG sinyallerini içermektedir. Burada, “2.1. Ağrı Tanımı ve Çeşitleri” bölümünde bahsedilen İngilizce'deki “pain” kelimesinin hem acı hem ağrıyı kapsamıyla

ilgili değinilen nokta öne çıkmaktadır. Bu verisetinde kastedilen “pain”, dışarıdan aktarılan ve anlık gelişen bir acıdır. İngilizce’de “acute pain” olarak sınıflandırılmaktadır.

The UNBC-McMaster Shoulder Pain Expression [6] veriseti ise omuz ağrısı çeken katılımcıların ağrıyan ve ağrımayan uzuvlarıyla yaptıkları bir dizi hareketin videoya alınması ve bu hareketleri yaparken katılımcıların yüz ifadelerinin kaydedilmesiyle oluşturulmuştur. Yüzlerden oluşan ve birçok duyguyu içeren diğer verisetlerinin aksine ağrı tanıma üzerine yoğunlaşmış bir verisetidir.

iCOPEvid [3], yenidoğan ünitesindeki bebeklerde ağrı tespiti problemlerinde kullanılan bir verisetidir. Buna göre, 49 bebeğin uyarılara maruz kaldığı, dinlenme anındaki ve akut ağrı durumlarını içeren 234 farklı video kaydedilip etiketlenmiştir.

Intelligent Sight and Sound: A Chronic Cancer Pain Dataset [7], 29 kanser hastasının akıllı telefon ile çekilmiş 509 videosu ve 189,999 kare ile birlikte Kısa Ağrı Envanteri(BPI)’nden uyarlanan, kişinin kendisi tarafından bildirilen ağrı skorlarını içermektedir.

X-ITE Pain Database [4], 134 katılımcının fazik (kısa) ve tonik (1 dakika uzunluğunda) ısı ve elektrik yoluyla acı verildiğinde gözlemlenen renkli ve termal kamerada çekilmiş yüz video, ses, elektrodermal aktivite(EDA), elektrokardiyogram(EKG), ve yüzey elektromiyografi (sEMG) sinyallerini içermektedir. Toplamda 24,000 fazik ve 800 tonik acı aktarımı ve katılımcıların buna verdiği tepkiyi içerir.

2.4.2. Yapay Zeka ile Ağrı Tanıma Teknikleri

Yapay zeka ile ağrı analizi konusunda literatürde çeşitli çalışmalar öne çıkmaktadır ve bu konuda farklı popüler veri setlerinden yararlanılmıştır. Bu çalışmada olduğu gibi fizyolojik sinyallerin kullanıldığı çalışmaların yanında ses ve görsel verilere dayalı analiz yapılan çalışmalar da literatürde yer almaktadır. Aynı zamanda çeşitli derin öğrenme modellerinin kullanıldığı çalışmalar literatürde yer almaktadır. Bu kısımda da farklı veri tipleri ile yapılan analizler, avantaj ve dezavantajları ile birlikte incelenmiştir.

2.4.2.1.Görsel Veriler ile Yapılan Çalışmalar

Teoh ve arkadaşları [28] dizdeki kireçlenme neden olduğu ağrı yoğunluğunu tahmin eden hibrit bir derin öğrenme modeli tasarlamıştır. Çalışmaya göre radyografi görselleri kullanılarak bir tahmin yapılmaktadır ve bu tahminler VGG16, GAP ve KNN'in kombinasyonundan oluşturulmuş hibrit bir model ile elde edilmektedir. Görsellerle yapılan bir başka çalışma [29] yüz ifadelerini içermektedir ve “acı var”, “acı yok” şeklinde ikili sınıflandırma yöntemini kullanmaktadır. CK+ yüz duygu tanıma verisetinden yararlanılarak CNN modeli ile özellik çıkarılmış, RNN modeli ile tahminler yapılmıştır. Sonuç olarak %97,2 oranında doğruluk elde edilmiştir. Pikulkaew ve ark. [30], yüz izleme teknolojisini kullanarak harekete dayalı acıyı yakalamayı amaçlar. Bunun için UNBC veri setinden ardışık resimler kullanılarak bir derin öğrenme modeli eğitilmiştir. Geliştirilen mekanizma ile acı üç farklı kategoride incelenmiştir: acısız, acı başlangıcı ve acılı. Yüz hareketleri ve etiketler kullanılarak eğitilen derin öğrenme modellerinde acısız, acı başlangıcı ve acılı sınıflandırmalarda sırasıyla %99,75, %92,93 ve %95,15 doğruluk elde edilmiştir.

2.4.2.2.Fizyolojik Sinyal Tabanlı Çalışmalar

Fizyolojik sinyallerden kas tepkisi ve vücut hareketlerini kaydeden sEMG ve IMU sinyallerini inceleyen bir çalışmada [31], kronik ağrı çeken insanların, ağrının verdiği hasardan korunmak için bilinçsizce belirli vücut hareketlerine uyum sağlaması ele alınmıştır. Bundan yola çıkılarak geliştirilen derin öğrenme modelleri yardımıyla hem ağrı seviyesi hem de ağrıya dayalı davranış sınıflandırması yapılmıştır. Bu alanda popüler bir veriseti olan EmoPain verisetinden yararlanılmıştır. Bu veriseti çok boyutlu olup katılımcıların IMU ve sEMG sensörlerini içermektedir. S-RNN ve GRU kombinasyonu ve Autoencoderlar kullanılarak bir model oluşturulmuştur ve %72.21 F1-Skoru elde edilmiştir. Harekete dayalı ağrı analizinde kas tepkilerinin haricinde aynı zamanda yüz ifadelerini de inceleyen çalışmalar literatürde yer almaktadır. Fizyolojik sinyal kullanılarak yapılmış çalışmalardan bir başkası da Salekin ve ark. [32] tarafından yürütülmüştür. Bu çalışmada yenidoğan postoperatif ağrının tespiti için derin öğrenme modelleri geliştirilmiştir. Hem akut ağrı hem de ameliyat sonrası ağrı gözlemlenmekte olup 45 yenidoğanın görsel, işitsel ve fizyolojik sinyal verileri toplanmıştır. Ağrının


yoğunluğu, N-PASS skorları ile etiketlenmiştir. Bilinear CNN Model ile hangi özelliklerin daha önemli olduğu tespit edilmiş ve daha sonrasında LSTM modeli ile ağrının yoğunluğu tahmin edilmiştir.

Literatürdeki çalışmalarda Elektrodermal Aktivite(EDA) sinyalinin ağrı analizinde önemli bir değişken olduğu görülmüştür. Bunlardan biri, Ajayi, T.A. ve arkadaşlarının [33] kronik ağrı çeken kanser hastası çocukları 24 saat boyunca Empatica E4 cihazı ile gözlemlediği çalışmadır ve ağrılı durum ve ağrısız durum arasında hastaların ortalama kalp atışının 16.4 bpm kadar arttığını, vücut sıcaklığının 3.5 °C kadar düştüğünü ve elektrodermal aktivitenin 0.27 azaldığını keşfetmişlerdir. Başka bir çalışmada [34] da ameliyat sonrası hastalar için ağrı analizi yapan yapay öğrenme modelleri geliştirilmiş ve bu modelleri beslemek için üretilen verisetine Empatica E4 akıllı saat cihazından alınan PPG ve EDA sinyalleri kaydedilmiştir. Başka bir çalışmada [35] EDA verisi kullanılarak akut ağrı tespiti yapan derin öğrenme modelleri geliştirilmiştir. Bu alandaki popüler verisetlerinden biri olan BioVid Heat Pain Database kullanılmıştır. Sinyal verisini işlemek için LSTM, CNN-LSTM, 1D-CNN mimarileri kullanılmıştır ve sonuç olarak kullanılan derin öğrenme modellerinin arasında en yüksek başarı, bir zaman evrişimli sinir ağı ve üst üste binmiş çift yönlü ve tek yönlü LSTM'in paralel hibrit mimarisi olup %77.8 F1-skoru elde etmiştir. Ngan ve arkadaşları [36] BioVid Heat Pain ve Emopain 2021 verisetlerini kullanarak ağrılı ve ağrısız durumların tespiti için LSTM ve Dikkat mekanizmasını kullanan bir derin öğrenme modeli geliştirmiştir.

2.5.Biyosinyal ile Çalışan Derin Öğrenme Mimarileri

2.5.1.LSTM

Uzun kısa süreli bellek (LSTM) [37], genel yinelemeli sinir ağlarının sahip olduğu kaybolan/patlayan gradyan sorununa çözüm olması için geliştirilmiştir [38] ve uzun vadeli değişimleri yakalayabilmektedir. LSTM, bellek blokları olarak bilinen, yinelemeli olarak bağlanmış alt ağlardan oluşur. Bellek bloklarının amacı, bilgi akışını düzenleyerek modelin bazı bilgileri kaybetmesinin ya da bazı detaylara fazla takılmasının önüne geçmektir, bunu da doğrusal olmayan kapı birimleri ile yapar. Genel itibariyle LSTM'in yapısı ve çalışma mekanizması Şekil 5'te belirtilmiştir.



Şekil 5: LSTM Mimarisi ve Çalışma Mekanizması (Kaynak: [39]).

$$a = f(W \cdot [x_t; y_{t-1}] + b)$$

$$g^{\{(i)\}} = \sigma(W_i \cdot [x_t; y_{t-1}] + b_i)$$

$$g^{\{(o)\}} = \sigma(W_o \cdot [x_t; y_{t-1}] + b_o)$$

$$g^{\{(f)\}} = \sigma(W_f \cdot [x_t; y_{t-1}] + b_f)$$

$$c_t = g^{\{(i)\}} \odot a + g^{\{(f)\}} \odot c_{t-1}$$

$$y_t = g^{\{(o)\}} \odot f(c_t)$$


Buna göre, input (g(i)) ve output (g(o)) kapıları içeri giren ve dışarı çıkan veriyi düzenlemeye hizmet ederken hücrenin hafızasını korumaktadır. Unutma kapısı (g(f)) ise verinin gerekmediği noktalarda hafıza hücrelerini temizlemek için kullanılmaktadır [39].

2.5.2.Dönüştürücü (Transformer)

Ashish Vaswani ve arkadaşları [40] geleneksel dizi dönüştürme modellerinin bir kodlayıcı(encoder) ve bir çözücü(decoder) içeren kompleks, tekrarlayan veya evrişimli sinir ağlarına dayandığını belirtmiş ve en iyi performans gösteren modellerin ayrıca, kodlayıcı ve çözücüyü bir dikkat(attention) mekanizması ile bağladığı yorumunu yapmıştır. Tekrarlama ve evrişimleri tamamen ortadan kaldırarak yalnızca dikkat mekanizmalarına dayanan bu mimariye Dönüştürücü adı verilmektedir ve bu modellerin daha paralelleştirilebilir olmasının yanında eğitim için önemli ölçüde zamandan tasarruf ettiği keşfedilmiştir. Dikkat mekanizmasının ana fikri, bazı ilgili detaylara odaklanmak ve geri kalan özellikleri seçici olarak gözardı etmektir, dikkat mekanizması sayesinde bir cümledeki birbirleriyle ilişkili kelimeler seçilebilir veya bir görseldeki farklı bölgeler öne

çıkarılabilir [41]. Dikkat, başlangıçta doğal dil işleme görevlerinde kullanılsa da [42] sonradan geniş bir alana yayılarak görüntü işleme, sinyal işleme gibi alanlarda da kullanılmış ve başarılı sonuçlar vermiştir.

[Şekil 6]'da bir Dönüştürücü (Transformer) mimarisi görülmektedir [40]. Encoder ve decoderdan oluşan bu mimaride encoder N=6 tane eş katman içermektedir ve her bir katmanın ikişer tane alt katmanı vardır. Bu alt katmanlardan ilki Multi-Head Self-Attention mekanizması, ikincisi ise basit, tam bağlı ileri beslemeli ağ (fully connected feed-forward network)'dır. Decoder katmanı da yine N=6 tane eş katmandan oluşur. Encoderdaki ilk iki katmana ek olarak üçüncü bir alt katman içerir, bu da Encoderın çıktısına Multi-Head Attention uygulayan bir katmandır.




Şekil 6: Dönüştürücü (Transformer) Mimarisi (Kaynak: [40]).

2.5.3. Dikkat (Attention)

Dikkat fonksiyonu, bir sorguyu(query) ve bir dizi anahtar-değer(key-value) çiftini bir çıktıya(output) eşlemektedir ve bu sayılan kavramların hepsi vektörlerden oluşmaktadır.

Değerlerin ağırlıklı toplamı hesaplanarak çıktı üretilir ve her bir değere atanmış ağırlık, sorgunun ilgili anahtarla olan uyumluluğu tarafından belirlenir [40].



Şekil 7: Dikkat(Attention)'in çalışma mekanizması (Kaynak: [43]).

Şekil 7’de Dikkat’in yapısı en temel haliyle görülmektedir. Buna göre, dikkatin çalışma mekanizması ikiye ayrılabilir: girdiler üzerinde dikkat dağılımını hesaplamak, ve dikkat dağılımına göre bağlam vektörünü (context vector) hesaplamak. Dikkat dağılımı hesaplanırken [43] sorgular(q) ile anahtarlar(K) arasındaki korelasyon, bir sonraki çıktıyı belirlemede sorguların anahtarlarla ilgili önemini yansıtan enerji puanı e ’yi elde etmek için skor fonksiyonu f ile hesaplanır:

$$e = f(q, K)$$

Dikkat yapısının çeşidine göre f fonksiyonları farklılık göstermektedir. Sonrasında e enerji skorları kullanılarak dikkat dağılım fonksiyonu g ile ağırlıklar hesaplanmaktadır:

$$\alpha = g(e)$$

g dağılım fonksiyonu softmax fonksiyonudur ve tüm enerji skorlarını bir olasılık dağılımında ifade etmektedir. Bazı araştırmacılar softmax yerine başka fonksiyonları da denemişlerdir. Sinir ağı bağlam vektörlerini hesapladıktan sonra, ‘değer’ olarak adlandırılan yeni bir veri özellik temsili ‘ V ’ tanıtılır. V ’nin her bir elemanı, K ’nın yalnızca bir elemanına karşılık gelmektedir. Dikkat değerleri ve ağırlıkları hesaplandıktan sonra, bağlam vektörü aşağıdaki gibi hesaplanır:

$$c = \phi(\{\alpha_i\}, \{v_i\})$$

Φ fonksiyonu değerler ve onlara karşılık gelen ağırlıkların olduğu bir vektör oluşturmaktadır. Φ fonksiyonunun genel kullanımı V değerlerinin ağırlıklı toplamını vermektir:

$$\mathbf{c} = \sum_{i=1}^n \tilde{\alpha}_i \mathbf{v}_i$$


2.5.4. Multi-Head Attention

Vaswani ve ark. [40], geliştirdikleri dikkat mimarisinde spesifik bir dikkat modelinden bahseder, bunun adı Ölçeklenmiş Nokta-Çarpım Dikkat (Scaled Dot-Product Attention)'tir. Buna göre, girdi, boyutu d_k olan sorgular ve anahtarlar ile boyutu d_v olan değerlerden oluşur. Sorgunun tüm anahtarlarla nokta çarpımları hesaplanıp her biri $\sqrt{d_k}$ 'ya bölünür ve değerlerin ağırlıkları için bir softmax fonksiyonu uygulanır.

“Pratikte, dikkat fonksiyonunu bir sorgu kümesi üzerinde aynı anda hesaplarız, bunları bir matris Q içine paketleriz. Anahtarlar ve değerler de sırasıyla matrisler K ve V içine paketlenir. Çıktılar matrisini şu şekilde hesaplarız:” (Vaswani, s. 4)

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V$$


Multi-head attention ise çoklu Ölçeklenmiş Nokta-Çarpım Dikkat katmanının bir arada çalışması ile oluşturulmuştur [Şekil 8].



Şekil 8: Multi-Head Attention Mimarisi (Kaynak: [40]).

3. YÖNTEM

Bu bölümde, verinin toplanmasından geliştirilen derin öğrenme modellerine kadar izlenen metodoloji ayrıntıları ile verilmiştir. Şekil 9’da görüldüğü üzere öncelikle ağrı analizi için toplanmış olan ham veri ve hastalardan alınan geribildirimleri içeren ağrı ölçeği verisine yer verilmiştir. Sonrasında farklı boyutlardaki sinyal verileri tek bir boyutta ifade edilmiş ve sinyal verileri ağrı ölçeği verisi ile etiketlenmiştir. Farklı frekanslara sahip RheumaPain, yani romatolojik ağrı verisetleri oluşturulmuştur. Bu veriseti, Çoklu Ağrı Veriseti adı verilen başka bir veriseti ile birleştirilerek zenginleştirilmiş ve yine çeşitli frekans boyutlarına sahip Ağrı Füzyonu (PainFusion) Veriseti oluşturulmuştur. Daha sonra, ağrı seviyeleri ve çeşitli ağrı türlerini tahmin etmek için farklı derin öğrenme modelleri geliştirilmiş ve bu modeller üç farklı yöntem ile eğitilmiştir. Bunlardan ilki, Şekil 9’da da 1 ile işaretlenen yöntem, yani modellerin RheumaPain Veriseti ile eğitilmesidir. Diğer yöntem, Şekil 9’daki 2 ile işaretlenmiş ve modellerin Ağrı Füzyonu Veriseti ile eğitilmesini içermektedir. 3. Yöntem ise modellerin önce Çoklu Ağrı Veriseti ile önceden eğitilmesi, daha sonra önceden eğitilmiş (pretrained) modellerin bazı katmanlarının dondurularak RheumaPain veriseti ile eğitilmelerini içermektedir. Şekil 9’da belirtilen üç yöntem ağrı seviyelerini derin öğrenme yardımı ile tahmin etmek için uygulanırken uygulanan diğer bir yöntem ağrı türünü tespit etmek için Ağrı Füzyonu Veriseti’nin kullanılmasıdır. Buna göre, dört farklı ağrı tipi ve ‘ağrı yok’ verisi üzerinden 5 sınıflı bir tahmin yapılmıştır.



Şekil 9: İzlenen yöntemin kısa özeti

3.1. Veri Toplama Protokolü

Bu çalışma; İstanbul Üniversitesi Cerrahpaşa Çocuk Sağlığı ve Hastalıkları Anabilim Dalı, Çocuk Romatoloji Anabilim Dalı, Fizyoterapi ve Rehabilitasyon Biriminde yürütülmüştür. Çeşitli romatolojik rahatsızlıklardan şikayetçi olan 5-18 yaş aralığındaki çocuk hastaların tedavi esnasındaki ve istirahat halindeki durumları gözlemlenmiştir. 31'i kadın ve 11'i erkek olmak üzere toplamda 42 hastadan veri alınmıştır. Tedaviler, Fizyoterapi ve Rehabilitasyon bölümü öğretim görevlileri tarafından hastalara tavsiye edilen bir dizi egzersizin uygulandığı anları içermektedir ve bu egzersizler çocuk romatoloji alanındaki çeşitli hastalıkların türüne göre farklılık göstermektedir. Hastaların koluna E4 Empatica giyilebilir cihazı takılmış ve bu cihaz yardımıyla hastaların fizyolojik sinyalleri toplanmıştır. Eşzamanlı olarak hastalara egzersiz ve istirahat esnasında Wong-Baker Faces Pain Scale yardımıyla hissettikleri ağrının yoğunluğu sorulmuştur. Egzersiz ve istirahat durumlarını kapsayan zaman dilimlerinde veri alınmıştır. Veriseti oluşturulurken bu süreler ağrının yoğun veya daha hafif hissedildiği zaman dilimleri göz önünde bulundurularak kesilmiş ve işlenmiştir. Şekil 10'da tedavi olan bir çocuk romatoloji hastasının egzersiz esnasındaki görüntüsüne yer verilmiştir.



Şekil 10: Cerrahpaşa Çocuk Acil Fizyoterapi ve Rehabilitasyon Bölümü'nde tedavi olan bir hasta

3.1.1.Ağrı Ölçeği

Ağrı ölçeği olarak uzman fizyoterapistlerin yönlendirmesi ile çocukların kendini daha iyi ifade edebileceği bir ölçek olan Wong-Baker Yüzler Ağrı Ölçeği seçilmiştir. Hem egzersiz hem istirahat esnasında hastalara bu ölçek yardımıyla kaç şiddetinde ağrı hissettikleri sorulmuştur. Çalışma Türkiye’de yapıldığı için ağrı ölçeğinin Türkçe versiyonu kullanılmıştır. Bu ölçek orijinal Wong-Baker ölçeğine benzemekle birlikte ağrı seviyeleri 0-10 yerine 0(Ağrı yok)-5(Çok şiddetli ağrı) skalasında ifade edilmiştir.

3.1.2.Sinyal Verisi


Hastaların ağrı seviyelerini kendilerinin rapor etmesinin yanında egzersiz esnasındaki vücut sinyalleri E4 Empatica giyilebilir cihazıyla kaydedilmiştir. E4 Empatica cihazında 4 farklı sensör bulunmaktadır. Bunlar; fotopletismografi(PPG), elektrodinamik aktivite(EDA/GSR), ivmeölçer ve kızılötesi sensördür.

PPG: Stres uyaranlarına yanıt olarak kan hacmi ve kan basıncındaki değişiklikler nedeniyle her atım aralığı için değişen kan hacmi nabzını (BVP) ölçer [44]. PPG, bir kaynaktan ışık yayarak ve hacimdeki kan miktarına bağlı olarak bu ışığın ne kadarının

kan tarafından emildiğini ölçerek çalışır. PPG cihazları genellikle kalp atış hızını (HR), kalp atış hızı değişkenliğini (HRV) ve ilgili bilgileri hesaplamak için kullanılır.

EDA/GSR ile sempatik sinir sistemi uyarılmaları ölçülür, ivmeölçer 3 eksenlidir ve harekete dayalı etkinliği yakalar, kızılötesi sensörü ve vücut sıcaklığındaki değişimleri takip edebilir. Birçok kimse için, duygu değişimleri, artan bilişsel iş yükü ya da fiziksel efor, beyin tarafından terleme düzeyini artırmak için cilde sinyal gönderilmesi ile sonuçlanır. Cilt yüzeyinde herhangi bir terleme hissedilmese bile yüzeyin altında kalan gözeneklerin dolmaya başlamasıyla elektrik iletkenliği fark edilir derecede artmaktadır [45]. Empatica E4, ciltteki elektrik iletkenliğini (direncin tersi) yakalamanın bir yolunu sağlar. Bunu, cilde temas eden iki elektrot arasından çok az miktarda akım geçirerek başarır. İletkenlik ölçüm birimleri microSiemens'tir (μS). EDA sinyali iki ayrı tipte gözlemlenebilir, bunlar tonik cilt iletkenlik düzeyi ve fazik cilt iletkenlik tepkisidir. Fazik iletkenlik bir olaya verilen tepkilerde oluşan ani değişimleri ve tepe noktalarını kapsarken tonik iletkenlik, cildin onlarca saniye ya da dakikalar içindeki iletkenliğinin yavaşça, bir eğri şeklinde değişimini kapsar. EDA sinyalinin toplanmasındaki temel amaç cilt tarafından ağrıya verilen tepkiyi yakalamaktır ve bunun ağrı deneyimleyen hastalar için önemli bir parametre olup olmadığı araştırılmıştır.

Aşağıdaki şekilde [Şekil 11], 17 yaşındaki bir kadın hastanın fizyoterapi egzersizi esnasındaki E4 Empatica cihazı ile alınmış sinyal verileri gözlemlenmektedir.



Şekil 11: Cinsiyet: Kadın, Yaş: 17, Hastalık Tanı: JIA, Ağrı Seviyesi(Egzersiz): 4, Ağrı Seviyesi(İstirahat): 0.

3.2.Verinin Önışlenmesi

RheumaPain verisetini oluşturmak için öncelikle farklı boyutlardaki sinyaller yeniden örneklenmiş, daha sonrasında egzersiz ve istirahati temsil eden zaman dilimleri, hastalardan fizyoterapi uzmanları eşliğinde alınan geri bildirimlere göre etiketlenmiştir.

3.2.1.Sinyallerin Yeniden Örneklenmesi

Sinyallerin frekansları alınan sinyalin cinsine göre farklılık göstermektedir. Elektrodermal aktivite(EDA) sinyalleri 4 Hz, kan hacmi nabızı(BVP) 64 Hz, ivmeölçer verisi (ACC(x,y,z)) 32 Hz, vücut sıcaklığı (TEMP) 4 Hz'dir. Buna göre sinyaller aynı frekans boyutlarında ifade edilecek şekilde upsampling ve downsampling metotları kullanılarak yeniden örneklenmiş ve bu sayede 4, 8, 16, 32, 64 Hz boyutlarında sinyalleri içeren beş farklı veriseti oluşturulmuştur. Ağrı seviyelerine göre verinin farklı Hz'lik frekanslardaki verisetlerinde dağılımı Tablo 1'de gösterilmiştir.


Tablo 1: Farklı frekans değerlerinde ifade edilen RheumaPain Veriseti

Frekans	0	1	2	3	4	5
4Hz	20444	12557	22407	14303	8461	2010
8Hz	40906	25124	44822	28584	16918	4014
16Hz	81830	50258	89650	57146	33832	8022
32Hz	163677	100526	179308	114270	67660	16038
64Hz	327371	201062	358622	228518	135316	32070

3.2.2. Verilerin Etiketlenmesi

Veri toplama sırasında hastaların egzersiz ve istirahat anları kronometre ile kaydedilmiş ve egzersizde ve istirahatte deneyimledikleri ağrı seviyesinin kaç olduğu sorulmuştur. Buna göre, sinyal verisindeki egzersiz ve istirahatlerin başlangıç ve bitiş anları göz önünde bulundurularak farklı zaman dilimleri için farklı etiketlemeler yapılmıştır. Şekil 12'de 18 yaşında JIA tanısı almış bir kadın hastanın sinyal verisi görülmektedir, hasta istirahat

esnasında 3 seviyesinde ve egzersiz esnasında 4 seviyesinde hissettiğini belirtmiştir, egzersiz durumlarını kırmızı ve istirahat durumlarını mavi ile zaman dilimlerine göre gösteren zaman serisi grafiği şekilde gösterilmiştir ve veriseti üzerindeki etiketlemeler şeklindeki zaman dilimleri göz önünde bulundurularak yapılmıştır.



Şekil 12: Cinsiyet: Kadın, Yaş: 18, Tanı: JIA, Ağrı Seviyesi(egzersiz): 4, Ağrı Seviyesi(istirahat): 3.

3.3. RheumaPain Veriseti


RheumaPain, hastaların fizyolojik sinyallerini, yaşlarını, cinsiyetlerini, hastalık teşhislerini ve dinlenme ve egzersiz anındaki ağrı seviyelerini içeren bir zaman serisi (time series) verisetidir. 42 çocuk romatoloji hastasından ortalama 8,59 dakika, toplam 361 dakikalık sinyal verisi toplanmıştır. Her bir kullanıcı için farklı ağrı seviyelerinin yer aldığı sinyaller gruplanmıştır. Bu sinyaller 8 Hertz’lik frekans için 100’er satırlık zaman serisi verisi ile ifade edilmiştir, bu da yaklaşık 12,5 saniyedir. Egzersiz esnasındaki ve istirahat anındaki farklı ağrı seviyelerini içeren zaman serileri örneklenmiştir. RheumaPain’de kullanıcıların ID’si, cinsiyeti, yaşı ve E4 Empatica Akıllı Saat yardımıyla toplanmış BVP, EDA, Aksonometrik veriler (x,y,z), vücut sıcaklığı, ağrı şiddeti ve hastalığın teşhisi verileri yer almaktadır. Verisetinin içeriği Tablo 2’deki gibidir.

Tablo 2: RheumaPain Verisetindeki özellikler, veri tipleri ve açıklamaları

Özellik Adı	Veri Tipi	Açıklama
Sex	object	Cinsiyeti belirtir.
Age	int64	Yaşı belirtir.
BVP	float64	Kalp atış hızını belirtir.
EDA	float64	Elektro dermal aktiviteyi belirtir.
X	float64	X eksenindeki hareketi belirtir.
Y	float64	Y eksenindeki hareketi belirtir.
Z	float64	Z eksenindeki hareketi belirtir.
Temperature	float64	Cildin yüzey sıcaklığını °C(Celcius) cinsinden belirtir.
Pain Scale	int64	Hastaların Faces Pain Scale’e verdiği 0-5 skalasındaki yanıtları içerir.
Diagnosis	object	Teşhisi konulan romatolojik hastalığın adını belirtir.


3.3.1. Popülasyon

Popülasyon, yaş ortalaması 13 olan 42 çocuk romatoloji hastasından oluşmaktadır. Hastaların 11’i erkek, 31’i kadındır. Hastaneye gelen çocuklarda en sık görülen hastalık türü 33 kişi ile JIA olarak öne çıkmaktadır [Şekil 13]. Bunun yanında, skolyoz ve Behçet gibi, dört temel hastalık kategorisine girmeyen hastalıklar ‘diğer’ başlığı altında değerlendirilmiştir. Erkek ve kadın katılımcılarda gözlemlenen yaş ve tanı dağılımları Şekil 13’te belirtilmiştir.



Şekil 13: a) Hastaların yaş dağılımları, b) Cinsiyete göre yaş dağılımları, c) Tanı dağılımları, d) Cinsiyete göre tanı dağılımları


Şekil 14’te, hastalıkların beş farklı grupta dağılımları gösterilmiştir. Bunlar, çocuk romatoloji hastalıklarını ele alan dört ana hastalık grubu (JIA, JDM, SLE, JSkl) ve ‘diğer’ grubudur. Oligoartiküler JIA, Romatoid Artrit ve Spondiloartropati’yi JIA kümesine dahil etmek mümkündür. Lupus, Skleroderma ve Dermatomiyoit kümelerinde ise yine kendileriyle aynı isme sahip olan hastalıklara raslanmaktadır. Ayrıca bir hastalığa sahip olan kitle ne kadar fazlaysa şekilde o kadar geniş kümelerle ifade edilmiştir. Gelen hastalardan Çocuk Romatoloji bölümünde tedavi olan ancak dört temel hastalık grubuna girmeyen Behçet ve Skolyoz hastalıklarına sahip olan hastalar ‘Diğer’ kümesinde kategorize edilmiştir.



Şekil 14: Çocuk romatoloji hastalıklarının dört ana grubu ve alt grupları

3.3.2. Ağrı Seviyelerinin Dağılımı

Şekil 15'te görülen ağrı seviyeleri Wong-Baker Yüzler Ağrı Ölçeği'ne göre 6 farklı seviye olup her birinden kaçar sinyal toplandığı gösterilmiştir. Buna göre, bütün hastalardan alınan toplam sinyal göz önünde bulundurulduğunda en fazla gözlemlenmiş olan ağrı seviyesi 2 olup 8 Hertz'e göre yaklaşık 25000 satırlık sinyal verisi toplanmıştır. En az gözlemlenen ağrı seviyesi ise en yüksek seviye olan 5'tir.



Şekil 15: 8 Hz'lik sinyal verisinde ağrı seviyeleri için toplanmış örnekler

3.4.Çoklu Ağrı Veriseti

Geliştirilen derin öğrenme modelini daha çok örnek ile test edebilmek adına İstanbul Kültür Üniversitesi Bilgisayar Mühendisliği Bölümü'nde toplanmış olan Çoklu Ağrı Veriseti kullanılmıştır. Bu veriseti, 18-26 yaş aralığındaki yetişkinlerden oluşan 43 erkek ve 56 kadın katılımcının baş ağrısı, sırt ağrısı, adet ağrısı ve ağrısız durumlardaki çeşitli biyosinyallerini (EDA, BVP, ACC, TEMP) içermektedir. Zaman serisi sinyalleri içeren bu verisetinde katılımcıların ağrı seviyeleri 5 ölçekli Likert Ağrı Ölçeği [46]'ne göre kaydedilmiştir.

Tablo 3: Çoklu Ağrı Veriseti özellikleri

Sütun Adı	Açıklama
BVP	Kalp atış hızını belirtir.
EDA	Elektro dermal aktiviteyi belirtir.
X	X eksenindeki hareketi belirtir.
Y	Y eksenindeki hareketi belirtir.
Z	Z eksenindeki hareketi belirtir.
TEMP	Cildin yüzey sıcaklığını °C(Celcius) cinsinden belirtir.
Pain Scale	1(hiç ağrı yok)-5(dayanılmaz ağrı) aralığındaki ağrı seviyelerini içerir.
Pain Type	'baş ağrısı', 'sırt ağrısı', 'adet ağrısı', 'ağrı yok' şeklinde sınıflara ayrılan ağrı tipi verisidir.


3.5. Verisetlerindeki Ağrı Ölçeklerinin Eşit Temsili

Likert Ölçeği'nde 1(ağrı yok) ile 5(dayanılmaz ağrı) arasındaki 5 ölçekli spektrum, Wong-Baker Yüzler Ağrı Ölçeği'nde 0(ağrı yok) ile 5(dayanılmaz ağrı) şeklinde 6 ölçek ile ifade edilmiştir. İki verisetini birleştirirken ölçeklerin eşit şekilde ifade edilmesi gerekli olacağından RheumaPain'in etiketleri, 5 ayrı ağrı seviyesi ile ifade edilecek şekilde düzenlenmiştir. Buna göre, 0 olan ağrı seviyesi 1 ile temsil edilmiş, 1(çok hafif ağrı) olan ağrı seviyesi ise 2(hafif ağrı)'nın içine eklenmiştir. Bu değişimler ışığında 4, 8, 16, 32, 64 Hz'lik RheumaPainScaled verisetleri oluşturulmuştur.

3.6. Ağrı Seviyesi Tahmini için Geliştirilen Derin Öğrenme Modelleri

3.6.1. LSTM ve Multi-Head Attention Modeli


Model [Şekil 16], giriş katmanında input olarak (100, 6) boyutunda değer alır. Veri 8 Hz için eğitildiğinde 100'er satırlık zaman serisi ve 4 farklı sinyal verisi (BVP, EDA, TEMP, ACC(x, y, z)) almaktadır, 12,5 saniye değeri her bir frekansta farklı ifade edileceğinden giriş katmanındaki girdi boyutu da farklı denemelerde güncellenmiştir (Ör: 16 Hz için (200, 6), 32 Hz için (400, 6)). Girdi alındıktan sonra sırasıyla aktivasyon fonksiyonu tanh olan 256, 128, 64, 64 birimlik LSTM katmanları ile eğitilir ve her bir LSTM katmanı bir öncekinin çıktısını alır. Bu sırada katmanlar arasında, modelin aşırı öğrenmesini (overfitting) azaltmak amacıyla Dropout uygulanır, Dropout sayesinde bazı nöronlar rastgele atılarak modelin karmaşıklığı azaltılmaya çalışılır. LSTM katmanlarından gelen çıktılar Multi-Head Attention katmanına girer, dikkat (attention) mekanizması kullanılarak modelin belli özelliklere odaklanması sağlanır. Multi-Head Attention katmanında, num_heads=4 ve key_dim=32 parametreleri belirtilmiştir. Bu, 4 başlık (head) ve her bir başlık için 32 boyutlu anahtar (key) vektörleri kullanılacağını belirtir. Dropout(0.5) işlemi de burada kullanılarak overfitting önlenir. Daha sonra modelin daha hızlı ve stabil olmasını sağlamak için Layer Normalization kullanılır. Layer Normalization'dan geçen çıktı, Flatten işlemi ile tek boyutlu hale getirilir, böylece tek boyutlu olan çıktı Dense katmanına girebilmektedir. Aktivasyon fonksiyonu ReLU olan Dense(256) katmanı ile yeni ağırlıklar belirlenerek 0.2'lik Dropout ile bu ağırlıklar Dense(5)'e aktarılır. Dense(5) katmanında Softmax aktivasyon fonksiyonu kullanılarak ağrı seviyeleri tahmin edilir.



Şekil 16: Multi-Head Attention ve LSTM Modeli

3.6.2. 1D-CNN Modeli


Geliştirilen bir başka model, 1 Boyutlu Evrişimsel Sinir Ağı (1D-CNN) modelidir. Bu modelin input katmanı da bir önceki kısımda bahsedilen modelde olduğu gibi farklı verisetleri için değişken olmakla birlikte sırasıyla 64, 128 ve 256 filtreye sahip, her birinin Kernel boyutu 3 ve aktivasyon fonksiyonu ReLU olan 1-boyutlu evrişimsel sinir ağı katmanları kullanılmaktadır. Bu katmanların arasında overfittingi engellemek için 0.5'lik dropout'lar bulunmaktadır. Daha sonra özellik haritasını düzleştirmeden önce Global Average Pooling 1D uygulanır ve ağırlıklar 256 nöronlu Dense katmanına aktarılır. Daha sonrasında çıkış katmanında Softmax fonksiyonu, 5 sınıflı veriseti için kullanılır.



Şekil 17: 1 Boyutlu Evrimsel Sinir Ağı Modeli

3.6.3. Dönüştürücü(Transformer) Modeli

Dönüştürücü(Transformer), geleneksel olarak Kodlayıcı-Çözücü (Encoder-Decoder) şeklinde bir mimari ile öne çıkmaktadır. Bunun nedeni çözücü yapısının makine çevirisi gibi görevlerde, başka bir zaman serisi ya da küme halinde bir veriyi üretmek için kullanılmasıdır. Ancak ağırlı tespiti yaparken çıktı olarak tek bir değer verildiği için bu durumda sadece encoder'ın olduğu bir dönüştürücü mimarisi kurmak mümkündür. Bu mimari [Şekil 18], iki farklı Multi-Head Attention katmanını içerir. Öncelikle 8 başlıklı ve 64 anahtar boyutlu multi-head attention katmanına girer ve burada ağırlıklar belirlenir. Daha sonrasında bu ağırlıklar 0.1 Dropout ile Layer Normalization'a aktarılır. Bu kısımda modelin performansını ve genelleştirmesini iyileştirmek amaçlanmıştır. Sonrasında çıktı ikinci bir Multi-head Attention katmanına girer ve oradan yine 0.1 oranında Dropout ve Layer Normalization işlemleri gerçekleştirilir. Daha sonrasında ilk ve ikinci Layer Normalization'dan çıkan çıktılar birbirine eklenir, sonrasında bunlar Flatten ile 1 boyutlu hale getirilerek Dense katmanlarına iletilir. 512 nöronlu ve 256 nöronlu Dense katmanlarından sonra çıktı katmanında Softmax aktivasyon fonksiyonu ile 5 ayrı ağırlı sınıftan birinin tahmini yapılır.



Şekil 18: Dönüştürücü (Transformer) Modeli

4. DENEYSEL SONUÇLAR

4.1.Ağrı Seviyesi Tespiti Sonuçları

Bu bölümde, metot kısmında bahsedilen derin öğrenme modelleri, farklı verisetleri ile ayrı ayrı eğitilerek test edilmiştir. Bunlar üç ana başlıkta incelenmiştir:

- Modellerin RheumaPain veriseti ile eğitilmesi
- Modellerin RheumaPain ile Çoklu Ağrı Veriseti'nin kombinasyonu olan PainFusion Veriseti ile eğitilmesi
- Çoklu Ağrı Veriseti ile eğitilen modellerin bazı katmanlarının dondurularak sonrasında RheumaPain ile eğitilmesi

Sonrasında modellerin performansları doğruluk (accuracy) ve F1 skoru cinsinden kıyaslanmış ve en başarılı modelin sonuçları gösterilmiştir. Geliştirilen bütün modellerde doğruluk ve hata metrikleri sırasıyla Accuracy ve Categorical Crossentropy olarak seçilmiştir. Model eğitilirken eğer overfitting başlarsa modelin eğitimini durdurması açısından EarlyStopping parametresi eklenmiştir. Bunun yanında ReduceLROnPlateau parametresi de aşırı öğrenme olduğu zaman öğrenme oranını azaltmak için ayarlanmıştır.

4.1.1.Derin Öğrenme Modellerinin RheumaPain Veriseti ile Eğitilmesi

Dönüştürücü(Transformer) ile 5 ölçekli ağrı seviyelerine göre yeniden düzenlenmiş RheumaPainScaled verisetleri eğitilmiş ve elde edilen değerler Tablo 4'te gösterilmiştir. Buna göre en az hata payı ve eğitim ve validasyon setleri arasındaki en az fark ile 4Hz Frekans değerine sahip RheumaPainScaled4Hz.csv veriseti ile eğitildiğinde model en yüksek tahminleri yapmıştır.

Tablo 4: Dönüştürücü (Transformers) Modelinin farklı frekans değerlerine sahip RheumaPain Verisetleri ile Eğitilmesi

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1- Skoru
4 Hz	%88	0,47	%84	0,65	%85
8 Hz	%80	0,64	%77	0,79	%82
16 Hz	%88	0,53	%83	0,66	%82

32 Hz	%88	0,64	%81	0,83	%85
64 Hz	%87	0,55	%80	0,76	%78

1D-CNN Modeli RheumaPain ile eğitildiğinde farklı 5 ölçekli RheumaPain verisetlerindeki dağılım Tablo 5'teki gibidir. En yüksek doğruluk ve en düşük kayıp oranlarına sahip veriseti yine 4 Hz'lik RheumaPainScaled verisetidir.

Tablo 5: 1D-CNN'in RheumaPainScaled'in farklı frekanslardaki verisetleri ile eğitildiğinde ortaya çıkan sonuçlar

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1- Skoru
4 Hz	%94	0,18	%91	0,28	%92
8 Hz	%95	0,16	%91	0,36	%90
16 Hz	%92	0,21	%87	0,43	%89
32 Hz	%94	0,30	%91	0,30	%91
64 Hz	%94	0,17	%89	0,39	%88

LSTM ve Multi-Head Attention Modeli RheumaPain ile eğitildiğinde ortaya çıkan sonuçlar Tablo 6'da gösterilmiştir. Eğitim ve validasyon setleri arasındaki aralığın geniş olmaması hedeflendiği için en tutarlı sonuçların model 32 Hz'lik veriseti ile eğitildiğinde gözlemlendiği söylenebilir.

Tablo 6-LSTM ve Attention Modelinin farklı Hz verilerine sahip RheumaPain Veriseti ile eğitiminden elde edilen sonuçlar

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1- Skoru
4 Hz	%95	0,24	%85	0,78	%87
8 Hz	%97	0,24	%84	0,85	%86

16 Hz	%77	1,21	%77	1,44	%73
32 Hz	%88	0,49	%81	0,80	%82
64 Hz	%80	1,004	%81	0,93	%83

4.1.2. Derin Öğrenme Modellerinin Ağrı Füzyonu Veriseti ile Eğitilmesi

1D-CNN Modeli, 8Hz’lik Ağrı Füzyonu Veriseti ile eğitilirken 32 yığın(batch size) ve 100 epoch’ta eğitilmiştir. Optimizer Adam olup öğrenme oranı 0.0001’dir. Ancak Erken Durdurma (Early Stopping) özelliği ile eğitim 62. Epoch’ta sonlandırılmıştır. 1D-CNN Modelinin farklı frekans değerlerine sahip kombine verisetlerindeki doğruluk, kayıp ve F1-skorları Tablo 7’de gösterilmiştir.

Tablo 7: 1D-CNN Ağrı Füzyonu Veriseti ile ağrı seviyesi tespiti için eğitilmesi sonucu çıkan doğruluk, kayıp ve F1-Skoru değerleri

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1-Skoru
4 Hz	%91	0,22	%90	0,27	%89
8 Hz	%93	0,16	%91	0,22	%92
16 Hz	%92	0,18	%90	0,29	%91
32 Hz	%93	0,16	%92	0,22	%91
64 Hz	%93	0,14	%92	0,15	%92

Dönüştürücü (Transformer) modelinin kombine verisetlerindeki performansı Tablo 8’de gösterilmiştir. Doğruluk ve hata oranları ele alındığında en başarılı sonuçları 16 Hz’lik verisetinde verdiği gözlemlenmektedir.

Tablo 8: Transformer Ağrı Füzyonu Veriseti ile ağrı seviyesi tespiti için eğitilmesi sonucu çıkan doğruluk, kayıp ve f1 skoru değerleri

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1-Skoru
---------	-------------------	----------------	-----------------------	--------------------	----------

4 Hz	%83	0,58	%82	0,63	%80
8 Hz	%83	0,61	%79	0,69	%81
16 Hz	%84	0,57	%82	0,62	%83
32 Hz	%77	0,76	%89	0,71	%76

LSTM ve Multi-Head Attention modelinin doğruluk, kayıp ve F1-Skoru değerleri Tablo 9’da gösterilmiştir. Buna göre, en başarılı sonuçlar 8 Hz’lik veri ile eğitildiğinde gözlemlenmiştir.

Tablo 9: LSTM ve Multi-Head Attention modelinin iki verisetinin birleştirilmesi ile oluşan Ağrı Füzyonu Veriseti ile eğitilmesi ve çıkan sonuçlar

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1- Skoru
4 Hz	%87	0,46	%86	0,52	%85
8 Hz	%88	0,41	%86	0,46	%87

4.1.3. Pretrained Modellerin Sonuçları

Bu deneyde, derin öğrenme modelleri Çoklu Ağrı Veriseti ile önceden eğitilmiş, sonrasında bazı katmanları dondurularak ancak modelin önceki öğrenme süreci korunarak RheumaPain Veriseti ile yeniden eğitilmiş ve sonuçları gözlemlenmiştir.

1D-CNN modeli Çoklu Ağrı Veriseti ile önceden eğitildiğinde sonuçlar Tablo 10’daki gibidir.

Tablo 10: 1D-CNN Modelinin Çoklu Ağrı Veriseti ile eğitilmesi sonucu elde edilen değerler

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1- Skoru
4 Hz	%93	0,16	%92	0,17	%93

8 Hz	%91	0,19	%92	0,18	%92
16 Hz	%93	0,15	%92	0,19	%92
32 Hz	%93	0,15	%92	0,21	%93
64 Hz	%93	0,15	%93	0,19	%75

1D-CNN modelinin Çoklu Ağrı Veriseti ile eğitilmiş katmanları dondurularak model RheumaPain ile eğitildiğinde çıkan sonuçlar Tablo 11’deki gibidir.

Tablo 11: Önceden eğitilmiş 1D-CNN modelinin RheumaPain ile eğitilmesi

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1- Skoru
4 Hz	%75	0,61	%75	0,67	%76
8 Hz	%79	0,52	%76	0,62	%76
16 Hz	%88	0,34	%79	0,75	%78
32 Hz	%86	0,38	%80	0,60	%75
64 Hz	%81	0,49	%73	0,86	%73

Dönüştürücü (Transformer) modeli Çoklu Ağrı Veriseti ile önceden eğitildiğinde sonuçlar Tablo 12’deki gibidir.

Tablo 12: Transformer modelinin Çoklu Ağrı Veriseti ile önceden eğitimi

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1- Skoru
4 Hz	%86	0,51	%83	0,62	%85
8 Hz	%85	0,55	%77	0,76	%76
16 Hz	%86	0,51	%83	0,55	%84
32 Hz	%88	0,43	%87	0,50	%87

64 Hz	%86	0,50	%78	0,80	%82
-------	-----	------	-----	------	-----

Dönüştürücü (Transformer) modelinin katmanları dondurularak RheumaPain Veriseti ile yeniden eğitildiğinde gözlemlenen sonuçlar Tablo 13'teki gibidir.

Tablo 13: Transformer Modelinin katmanları dondurularak model RheumaPain ile eğitildiğinde elde edilen sonuçlar

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1-Skoru
4 Hz	%82	0,55	%81	0,60	%81
8 Hz	%82	0,53	%76	0,71	%78
16 Hz	%79	0,62	%81	0,62	%79
32 Hz	%81	0,54	%80	0,66	%83
64 Hz	%82	0,48	%73	0,70	%73

LSTM ve Dikkat(Attention) modelinin önce Çoklu Ağrı Veriseti ile önceden eğitiminde elde edilen sonuçlar Tablo 14'teki gibidir.

Tablo 14: LSTM ve Dikkat(Attention) Modelinin Çoklu Ağrı Veriseti ile önceden eğitilmesi sonucu elde edilen bulgular

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1-Skoru
4 Hz	%89	0,40	%86	0,52	%89
8 Hz	%90	0,34	%89	0,38	%91
16 Hz	%90	1,02	%82	1,26	%81
32 Hz	%89	0,42	%88	0,45	%91
64 Hz	%89	0,42	%88	0,46	%90

Önceden eğitilmiş **LSTM ve Dikkat** modelinin katmanlarının dondurularak RheumaPain ile eğitilmesi sonucu elde edilen bulgular Tablo 15’teki gibidir.

Tablo 15: Önceden eğitilmiş LSTM ve Dikkat modelinin RheumaPain ile yeniden eğitimi

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1- Skoru
4 Hz	%81	0,54	%78	0,74	%75
8 Hz	%80	0,59	%75	0,87	%74
16 Hz	%90	0,36	%85	0,78	%84
32 Hz	%80	0,59	%76	0,87	%74
64 Hz	%81	0,62	%68	1,14	%70

4.2.Ağrı Türü Tespiti Sonuçları

Ağrı türünü tespit etmek için RheumaPain ve Çoklu Ağrı verisetlerinin birleşimi olan Ağrı Füzyonu Verisetinde ağrı seviyelerinin yanında ağrı tipleri de etiketlenmiştir. Bunlar, 4 farklı ağrı tipi(baş ağrısı, sırt ağrısı, adet ağrısı ve romatolojik ağrı) ve ‘ağrı yok’ şeklindeki etiketlemedir. Geliştirilen derin öğrenme modelleri, ağrı türünü tespit etmek için eğitilmiş ve elde edilen sonuçlar aşağıda verilmiştir.

1D-CNN modeli için elde edilen sonuçlar Tablo 16’da verilmiştir. Buna göre, en başarılı sonuçlar eğitim, validasyon ve test setlerinde elde edilen sonuçların birbirine yakınlığı göz önünde bulundurulduğunda 64 Hertzlik PainFusion Veriseti ile elde edilmiştir.

Tablo 16: 1D-CNN modelinin ağrı tespiti için PainFusion Veriseti ile eğitilmesi

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1- Skoru
4 Hz	%86	0,30	%83	0,43	%76
8 Hz	%86	0,28	%83	0,42	%78
16 Hz	%85	0,32	%84	0,37	%79

32 Hz	%85	0,32	%81	0,45	%77
64 Hz	%83	0,36	%82	0,41	%79

Dönüştürücü (Transformer) modeli için sonuçlar Tablo 17’de gösterilmiştir. Buna göre, modelin performansı beklenenin altında kaldığından dolayı bu bölümün ilerleyen kısımlarında model farklı bir mimari ile ifade edilmiştir.

Tablo 17: Dönüştürücü (Transformer) modelinin ağırlı tespiti için PainFusion Veriseti ile eğitilmesi

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1-Skoru
4 Hz	%66	0,93	%66	0,96	%59
8 Hz	%80	0,73	%68	1,04	%55
16 Hz	%78	0,71	%72	0,86	%62
32 Hz	%86	0,59	%64	1,22	%48
64 Hz	%71	0,83	%69	0,89	%62

LSTM ve Dikkat(Attention) modelinin PainFusion ile eğitimi sonucu elde edilen çıktılar Tablo 18’de gösterilmiştir.

Tablo 18: LSTM ve Dikkat(Attention) modelinin ağırlı tespiti için PainFusion Veriseti ile eğitilmesi

Frekans	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1-Skoru
4 Hz	%84	0,50	%77	0,73	%70
8 Hz	%83	0,55	%79	0,72	%72
16 Hz	%82	0,58	%77	0,73	%75
32 Hz	%86	0,80	%75	1,35	%63

64 Hz	%85	0,71	%81	0,96	%74
-------	-----	------	-----	------	-----

Dönüştürücü(Transformer) modelinden 8 Hz ve 32 Hz'lik ağrı sınıflandırma datasetlerinden çok düşük bir doğruluk alındığı için model 1D-CNN, Transformer Encoder ve Dense yapılarını içeren başka bir versiyona güncellenmiştir. Çıktıları Tablo 19'da belirtilmiştir.

Tablo 19: 1D-CNN, Transformer ve Dense yapısını içeren modelin ağrı tespiti için PainFusion ile eğitimi sonucu elde edilen değerler


Veriseti	Doğruluk (Eğitim)	Kayıp (Eğitim)	Doğruluk (Validasyon)	Kayıp (Validasyon)	F1- Skoru
8 Hz	%85	0,41	%80	0,60	%70
32 Hz	%83	0,52	%78	0,73	%69
64 Hz	%82	0,51	%81	0,59	%75

5. TARTIŞMA

Çalışma yapılırken karşılaşılan önemli noktalardan biri, çocuk hastalarla çalışıldığı için çocukların ağrılarını ifade ederken hissettikleri ağrının şiddetinin bilincinde olmama ihtimalleridir. Bir çocuk yoğun bir acı hissedip ağlıyorken ağrı seviyesi 1'i, yani 'çok hafif ağrı'yı seçebilmektedir. Ya da acıyla ilgili çok tepki vermeden ağrı seviyesi 5'i yani 'dayanılmaz ağrı'yı seçebilmektedir. Bu durumda, hastaya egzersizi yaptıran uzman fizyoterapistin fikri alınarak çalışmaya yön verilmiştir.


Ağrı analizini çeşitli derin öğrenme modelleri ile gerçekleştirebilmek adına farklı durumlar ve farklı derin öğrenme mimarileri denenmiştir. 3 farklı model 15 farklı çok modlu zaman serisi sinyali içeren veriseti ile eğitilmiştir. Ağrının şiddetini tespit etmek için üç farklı yöntem denenmiştir. İlk yöntem modellerin yalnızca RheumaPain Veriseti ile eğitilmesidir ve bu konuda en başarılı çıktılar %92 F1-Skoru ile 1D-CNN modelinde gözlemlenmiştir. İkinci yöntem modellerin RheumaPain ve Çoklu Ağrı verisetlerinin birleşimi olan PainFusion Veriseti ile eğitimidir ve burada da en başarılı çıktılar yine %92 F1-Skoru ile 1D-CNN modelinde gözlenmiştir. Üçüncü yöntemde ise modellerin Çoklu Ağrı Veriseti ile önceden eğitilip sonra katmanlarının dondurulması ve RheumaPain ile yeniden eğitilerek doğruluğunun artırılması hedeflenmiş ancak RheumaPain ile eğitim sonucu elde edilen sonuçlar, Çoklu Ağrı Veriseti ile elde edilen sonuçların gerisinde kalmıştır.

Ağrı şiddeti tespiti konusunda en başarılı model olan 1D-CNN modelinin eğitim ve validasyon setlerindeki doğruluk ve kayıp grafiği Şekil 19'daki gibidir. Buna göre, eğitim setindeki doğruluk oranı %92,36'ya ulaşmışken validasyon setindeki doğruluk oranı %91,33'e ulaşmıştır.



Şekil 19- 1D-CNN modelinin 8 Hz’lik Ağrı Füzyonu Veriseti ile eğitilmesi ile ortaya çıkan doğruluk ve kayıp grafikleri

1D-CNN Modelinin 8 Hz’lik Ağrı Füzyonu Veriseti ile eğitildikten sonraki Hata Matrisi ve F1-Skor Tablosu Şekil 20’de belirtilmiştir. Buna göre, modelin ağrı seviyesi 5 olan yani en yüksek ağrıyı içeren durumları tahmin etmede en yüksek başarıyı gösterdiği öne sürülebilir, F1-Skor Tablosunda da %96,4 ile en yüksek F1 skorunun ağrı seviyesi 5 olduğu gözlemlenmektedir. Daha sonrasında %95,8 ile ağrı seviyesi 1, sonrasında 4, 2, ve 3 gelmektedir.



Şekil 20-8 Hz’lik Ağrı Füzyonu Veriseti ile eğitilen 1D-CNN modelinin Hata Matrisi ve F1-Skor Tablosu

Modeller RheumaPain Veriseti ile eğitildiğinde daha gürültülü öğrenme eğrilerine sahip olmakla birlikte modellerin öğrenebilme kapasitesinin Ağrı Füzyonu Veriseti ile eğitilmelerine kıyasla daha fazla olduğu görülmüştür. Bunun nedeninin, RheumaPain ve Çoklu Ağrı Verisetlerinin öne çıkan farklı bir özelliği olabileceği tahmin edilmektedir. Bu

özellik, Çoklu Ağrı Veriseti'nde çoğunlukla süreklilik gösteren, yani kronik bir ağrının ortalama 20 dakika boyunca toplanması, ancak RheumaPain Veriseti'nde kronik ağrılar da olmakla birlikte bazı vakalarda ağrının anlık batma gibi şekillerde, egzersiz esnasında yaklaşık 10-15 saniyelikliğine açığa çıkması ve sönümlenmesi olabilir. Bu durumda iki farklı veriseti yerine sadece RheumaPain ile çalışılınca daha stabil öğrenme eğrileri açığa çıkabilmektedir. Benzer bir durumla önceden eğitilmiş modellerde de karşılaşılmıştır. Çoklu Ağrı Veriseti ile eğitilen modeller RheumaPain ile aynı başarıyı gösterememiştir, bunun nedeni iki verisetinin farklı karakteristik özellikler taşımasıdır.

Ağrının türünü tespit etmek için LSTM ve Dikkat, 1D-CNN ve Dönüştürücü mimarileri oluşturulmuş ve FusionPain Veriseti ile modeller eğitilerek ağrı seviyesi tespiti yapılmıştır. FusionPain'in çeşitli frekans boyutlarını içeren farklı verisetleri ile modeller eğitilmiş ve sırasıyla en başarılı sonuçlar LSTM ve Dikkat için %75, Dönüştürücü için %75 ve 1D-CNN için %79 F1-Skoru ile bulunmuştur.

Literatürdeki diğer çalışmalar ile kıyaslandığında bu çalışmanın çok modlu sinyal verisi ile yapılan ağrı şiddeti tahmini konusunda literatüre sağladığı katkı, Tablo 20'de gösterilmiştir.

Tablo 20: Bu çalışmanın literatürdeki diğer çalışmalarla ağrı şiddeti tespiti bağlamında kıyaslanması

Çalışma	Sinyal Verisi	Sınıf Sayısı	Doğruluk	F1-Skoru
Subramanian, A. ve ark. (2023) [34]	EKG, EDA, EMG, RR	2	%81,08	-
J. O. Pinzon-Arenas, Y. ve ark. (2023) [35]	EDA	2	%91,5	%77,8
Phan, N. ve ark. (2023) [36]	EDA, EKG, EMG	2, 5	%75,36	F1-P0:%85,34 F1-P1:%23,01
Bu çalışma	EDA, PPG, ACC, TEMP	5	%92,36	%91,5

6. SONUÇ

Ağrı, rahatsız edici ve vücudu uyaran bir deneyim olarak tanımlanmakta ve karmaşık doğası gereği kişiden kişiye değişkenlik gösterebilmektedir. Hastalıkların ya da geçici bir rahatsız edici durumun erken teşhisi ve önlenmesi açısından ağrıyı tespit edebilen sistemler geliştirebilmek oldukça önemlidir. Özellikle kendini ifade edemeyen hastaların (Ör: felçli hastalar, komadaki hastalar, yaşlılar, bebekler) ne hissettiğini dışarıdan gözlemleyebilecek bir sistemin varlığı bu hastaların acısını hafifletebilir. Bu sayede ağrı analizi ve derin öğrenme konusunda birçok farklı çalışma yapılmış ve farklı modeller geliştirilmiştir.

Romatolojik hastalıklar da ağrının erkenden fark edilmesi gereken ve önlem alınması gereken rahatsızlıklar grubuna girer. Çünkü romatolojik hastalıklara sahip insanlarda gözlemlenen bir durum, ağrıyı hissedemeyeceği pozisyonlarda durarak acılarını hafifletmeye çalışmalarıdır. Ancak bu durum hastalığın ilerlemesine neden olmakta ve çeşitli duruş bozuklukları, kemik eğrilikleri gibi durumları ön plana çıkarmakta, hastalığın tedavisini güçleştirmektedir. Tedavi için başlangıçta acı ve ağrı veren egzersizler yaparak kasların ve eklemlerin açılması sağlanmalıdır. Yetişkinler bunu başarabilirken çocuklar aynı bilinçliliğe sahip olamadığı için romatolojik hastalıklar çocuklarda daha sessiz ve yıkıcı bir şekilde ilerleyebilmektedir. Bunun için çocuk romatoloji hastalarında ağrı analizi yapan bir sistem geliştirilmesi fikri ortaya atılmıştır.

Bu çalışmada, ağrının şiddetinin ve türünün tespitinin derin öğrenme modelleri ile yapılması amaçlanmıştır. Bunun için Cerrahpaşa Hastanesi Çocuk Acil Bölümü'nde tedavi gören çocuk romatoloji hastalarının çok modlu sinyal verisi alınarak RheumaPain isimli, EDA, BVP, ACC ve TEMP biyosinyallerini, hastalar tarafından Wong-Baker Yüzler Ağrı Ölçeği ile etiketlenmiş ağrı seviyelerini, hastaların cinsiyet, yaş, hastalık türü bilgilerini içeren bir veriseti oluşturulmuştur. Sonrasında ağrı tespiti için çeşitli derin öğrenme modelleri geliştirilmiş ve en iyi çıkan sonuç %92 F1-Skoru ile 1D-CNN modelinde bulunmuştur. Ağrının türünün tespit edilmesi için RheumaPain Veriseti'nin Çoklu Ağrı Veriseti isimli başka bir veriseti ile kombinasyonundan oluşmuş FusionPain veriseti kullanılmış ve geliştirilen derin öğrenme modelleri baş ağrısı, sırt ağrısı, adet ağrısı ve romatolojik ağrı ve ağrı yok şeklinde etiketlenen beş farklı ağrı sınıfını çok modlu

fizyolojik sinyal bilgisi ile tahmin etmek üzere eğitilmiştir. Bunun sonucunda %79 F1-Skoru ile 1D-CNN modeli en yüksek sonuçları vermiştir.



7. KAYNAKÇA

- 1- Raja, S.N. et al. (2020) ‘The Revised International Association for the Study of Pain Definition of pain: Concepts, challenges, and compromises’, *Pain*, 161(9), pp. 1976–1982. doi:10.1097/j.pain.0000000000001939.
- 2- S. Walter et al., "The biovid heat pain database data for the advancement and systematic validation of an automated pain recognition system," 2013 IEEE International Conference on Cybernetics (CYBCO), Lausanne, Switzerland, 2013, pp. 128-131, doi: 10.1109/CYBConf.2013.6617456.
- 3- Brahnam, S. et al. (2020) ‘Neonatal pain detection in videos using the ICOPEVID dataset and an ensemble of descriptors extracted from gaussian of local descriptors’, *Applied Computing and Informatics* [Preprint]. doi:10.1016/j.aci.2019.05.003.
- 4- Othman, E(2022). 2.1. X-ITE Pain Database. Bio-protocol Preprint. bio-protocol.org/prep1603.
- 5- M. S. H. Aung et al., "The Automatic Detection of Chronic Pain-Related Expression: Requirements, Challenges and the Multimodal EmoPain Dataset," in *IEEE Transactions on Affective Computing*, vol. 7, no. 4, pp. 435-451, 1 Oct.-Dec. 2016, doi: 10.1109/TAFFC.2015.2462830.
- 6- P. Lucey, J. F. Cohn, K. M. Prkachin, P. E. Solomon and I. Matthews, "Painful data: The UNBC-McMaster shoulder pain expression archive database," 2011 IEEE International Conference on Automatic Face & Gesture Recognition (FG), Santa Barbara, CA, USA, 2011, pp. 57-64, doi: 10.1109/FG.2011.5771462.
- 7- Ordun, C., Cha, A. N., Raff, E., Gaskin, B., Hanson, A., Rule, M., Purushotham, S., & Gulley, J. L. (2022). Intelligent Sight and Sound: A Chronic Cancer Pain Dataset.
- 8- Subramanian, A. et al. (2023) Multimodal Pain Recognition in postoperative patients: A machine learning approach [Preprint]. doi:10.1101/2023.06.07.23291094.

- 9- Cazzola, M. et al. (2014) 'Physiopathology of pain in rheumatology', *Reumatismo*, 66(1), pp. 4–13. doi:10.4081/reumatismo.2014.758.
- 10- Weiner, R.S. (Ed.). (2001). *Pain Management: A Practical Guide for Clinicians*, Sixth Edition (6th ed.). CRC Press. <https://doi.org/10.1201/9781420093193>
- 11- 2001 Blackwell Science Ltd, *Journal of Clinical Nursing*, 10, 697-706
- 12- Begum, Mst. Rabea & Hossain, Mohammad. (2019). VALIDITY AND RELIABILITY OF VISUAL ANALOGUE SCALE (VAS) FOR PAIN MEASUREMENT. 2. 394-402.
- 13- Karcioğlu, O. Topacoglu, H. Dikme, O. Dikme, O. A systematic review of the pain scales in adults: Which to use?, <https://doi.org/10.1016/j.ajem.2018.01.008>.
- 14- Carl L von Baeyer, "Children's Self-Reports of Pain Intensity: Scale Selection, Limitations and Interpretation", *Pain Research and Management*, vol. 11, Article ID 197616, 6 pages, 2006. <https://doi.org/10.1155/2006/197616>
- 15- Downie WW, Leatham PA, Rhind VM, Wright V, Branco JA, Anderson JA. Studies with pain rating scales. *Ann Rheum Dis* 1978; 37: 378-81
- 16- Hjermstad, M.J. et al. (2011) 'Studies comparing numerical rating scales, verbal rating scales, and visual analogue scales for assessment of pain intensity in adults: A systematic literature review', *Journal of Pain and Symptom Management*, 41(6), pp. 1073–1093. doi:10.1016/j.jpainsymman.2010.08.016.
- 17- Hicks CL, von Baeyer CL, Spafford PA, van Korlaar I, Goodenough B. The Faces Pain Scale-Revised: toward a common metric in pediatric pain measurement. *Pain*. 2001 Aug;93(2):173-183. doi: 10.1016/S0304-3959(01)00314-1. PMID: 11427329.
- 18- Home - Wong-Baker Faces Foundation (2020) Wong. Available at: <https://wongbakerfaces.org/> (Accessed: 24 June 2024).
- 19- Melzack, R. and Raja, S.N. (2005) 'The mcgill pain questionnaire', *Anesthesiology*, 103(1), pp. 199–202. doi:10.1097/00000542-200507000-00028.
- 20- Melzack R: The McGill Pain Questionnaire: major properties and scoring methods. *Pain* 1975; 1:277–99

- 21- Raza, K. et al. (2011) ‘Delays in assessment of patients with RHEUMATOID ARTHRITIS: Variations across Europe’, *Annals of the Rheumatic Diseases*, 70(10), pp. 1822–1825. doi:10.1136/ard.2011.151902.
- 22- Knitza J, Knevel R, Raza K, Bruce T, Eimer E, Gehring I, Mathsson-Alm L, Poorafshar M, Hueber AJ, Schett G, Johannesson M, Catrina A, Klareskog L, JPAST Group Toward Earlier Diagnosis Using PainFusion eHealth Tools in Rheumatology: The Joint Pain Assessment Scoring Tool (JPAST) Project *JMIR Mhealth Uhealth* 2020;8(5):e17507 doi: 10.2196/17507
- 23- K. Barut, A. Adrovic, S. Şahin, and Ö. Kasapçopur, “Juvenile Idiopathic Arthritis”, *Balkan Medical Journal*, vol. 34, no. 2, pp. 90–101, 2017.
- 24- 6- Batthish, M., Feldman, B.M. Juvenile Dermatomyositis. *Curr Rheumatol Rep* **13**, 216–224 (2011). <https://doi.org/10.1007/s11926-011-0167-9>
- 25- 5- D. P. M. SYMMONS, J. A. SILLS, S. M. DAVIS, THE INCIDENCE OF JUVENILE DERMATOMYOSITIS: RESULTS FROM A NATION-WIDE STUDY, *Rheumatology*, Volume 34, Issue 8, August 1995, Pages 732–736, <https://doi.org/10.1093/rheumatology/34.8.732>
- 26- H. Lythgoe, McCann LJ, C.M. Hedrich, M. Aringer, Classification of systemic lupus erythematosus in children and adults, *Clinical Immunology*, Volume 234, 2022, 108898, ISSN 1521-6616, <https://doi.org/10.1016/j.clim.2021.108898>.
- 27- Zulian, F., Tirelli, F. Treatment in Juvenile Scleroderma. *Curr Rheumatol Rep* **22**, 45 (2020). <https://doi.org/10.1007/s11926-020-00910-x>
- 28- Y. X. Teoh, A. Othmani, S. L. Goh, J. Usman and K. W. Lai, "Predicting Knee Osteoarthritis Pain Severity through A Deep Hybrid Learning Model: Data from the Osteoarthritis Initiative," *2023 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, Istanbul, Turkiye, 2023, pp. 4148-4153, doi: 10.1109/BIBM58861.2023.10385415.

- 29- P. Rodriguez et al., "Deep Pain: Exploiting Long Short-Term Memory Networks for Facial Expression Classification," in *IEEE Transactions on Cybernetics*, vol. 52, no. 5, pp. 3314-3324, May 2022, doi: 10.1109/TCYB.2017.2662199.
- 30- K. Pikulkaew, W. Boonchieng, E. Boonchieng and V. Chouvatut, "2D Facial Expression and Movement of Motion for Pain Identification With Deep Learning Methods," in *IEEE Access*, vol. 9, pp. 109903-109914, 2021, doi: 10.1109/ACCESS.2021.3101396.
- 31- M. M. Dehshibi, T. Olugbade, F. Diaz-de-Maria, N. Bianchi-Berthouze and A. Tajadura-Jiménez, "Pain Level and Pain-Related Behaviour Classification Using GRU-Based Sparsely-Connected RNNs," in *IEEE Journal of Selected Topics in Signal Processing*, vol. 17, no. 3, pp. 677-688, May 2023, doi: 10.1109/JSTSP.2023.3262358.
- 32- M. S. Salekin, G. Zamzmi, D. Goldgof, R. Kasturi, T. Ho and Y. Sun, "First Investigation into the Use of Deep Learning for Continuous Assessment of Neonatal Postoperative Pain," *2020 15th IEEE International Conference on Automatic Face and Gesture Recognition (FG 2020)*, Buenos Aires, Argentina, 2020, pp. 415-419, doi: 10.1109/FG47880.2020.00082.
- 33- Ajayi TA, Salongo L, Zang Y, Wineinger N, Steinhubl S. Mobile Health-Collected Biophysical Markers in Children with Serious Illness-Related Pain. *J Palliat Med*. 2021 Apr;24(4):580-588. doi: 10.1089/jpm.2020.0234. Epub 2020 Dec 22. PMID: 33351729; PMCID: PMC7987367.
- 34- Subramanian, A. et al. (2023) Multimodal Pain Recognition in postoperative patients: A machine learning approach [Preprint]. doi:10.1101/2023.06.07.23291094.
- 35- J. O. Pinzon-Arenas, Y. Kong, K. H. Chon and H. F. Posada-Quintero, "Design and Evaluation of Deep Learning Models for Continuous Acute Pain Detection Based on Phasic Electrodermal Activity," in *IEEE Journal of Biomedical and Health Informatics*, vol. 27, no. 9, pp. 4250-4260, Sept. 2023, doi: 10.1109/JBHI.2023.3291955.

- 36- Phan, Ngan & Iyortsuun, Ngumimi & Pant, Sudarshan & Yang, Hyung-Jeong & Kim, S.H.. (2023). Pain Recognition With Physiological Signals Using Multi-Level Context Information. IEEE Access. PP. 1-1. 10.1109/ACCESS.2023.3248654.
- 37- Gers, Felix & Schmidhuber, Jürgen & Cummins, Fred. (2000). Learning to Forget: Continual Prediction with LSTM. Neural computation. 12. 2451-71. 10.1162/089976600300015015.
- 38- Van Houdt, G., Mosquera, C. & Nápoles, G. A review on the long short-term memory model. Artif Intell Rev 53, 5929–5955 (2020). <https://doi.org/10.1007/s10462-020-09838-1>
- 39- A. Pulver and S. Lyu, "LSTM with working memory," 2017 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, USA, 2017, pp. 845-851, doi: 10.1109/IJCNN.2017.7965940.
- 40- Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Łukasz Kaiser, and Illia Polosukhin. 2017. Attention is all you need. In Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17). Curran Associates Inc., Red Hook, NY, USA, 6000–6010.
- 41- Phan, Ngan & Iyortsuun, Ngumimi & Pant, Sudarshan & Yang, Hyung-Jeong & Kim, S.H.. (2023). Pain Recognition With Physiological Signals Using Multi-Level Context Information. IEEE Access. PP. 1-1. 10.1109/ACCESS.2023.3248654.
- 42- Bahdanau, Dzmitry & Cho, Kyunghyun & Bengio, Y.. (2014). Neural Machine Translation by Jointly Learning to Align and Translate. ArXiv. 1409.
- 43- Zhaoyang Niu, Guoqiang Zhong, Hui Yu, A review on the attention mechanism of deep learning, Neurocomputing, Volume 452, 2021, Pages 48-62, ISSN 0925-2312, <https://doi.org/10.1016/j.neucom.2021.03.091>.

- 44- Campanella, S.; Altaleb, A.; Belli, A.; Pierleoni, P.; Palma, L. A Method for Stress Detection Using Empatica E4 Bracelet and Machine-Learning Techniques. *Sensors* **2023**, *23*, 3565. <https://doi.org/10.3390/s23073565>
- 45- What should I know to use EDA data in my experiment? Available at: (No date). <https://support.empatica.com/hc/en-us/articles/203621955-What-should-I-know-to-use-EDA-data-in-my-experiment> (Accessed: 24 June 2024).
- 46- Mellor, D. and Moore, K.A. (2013) 'The use of Likert scales with children', *Journal of Pediatric Psychology*, 39(3), pp. 369–379. doi:10.1093/jpepsy/jst079.