

Çok Modlu Biyosinyallerle Akut Ağrıların Makine Öğrenmesiyle Tespiti

Cüneyt ÖZDEMİR*

Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Siirt Üniversitesi, Siirt, Türkiye.

<https://orcid.org/0000-0002-9252-5888>

Araştırma Makalesi

Geliş Tarihi

07/07/2025

Kabul Tarihi

07/08/2025

DOI

[10.70562/tubid.1736747](https://doi.org/10.70562/tubid.1736747)

Özet

Ağrının subjektif doğası, nesnel değerlendirme yöntemlerinin geliştirilmesini zorunlu kılmaktadır. Bu çalışma, giyilebilir sensörlerden elde edilen çok modlu fizyolojik sinyalleri kullanarak farklı akut ağrı tiplerini otomatik olarak sınıflandırmanın fizibilitesini ve etkinliğini araştırmaktadır. Kamuoyuna açık PhysioPain Dataset'ten alınan ve 99 katılımcıya ait baş ağrısı, sırt ağrısı, menstrüel ağrı ve ağrısız durumlardaki fizyolojik veriler analiz edilmiştir. Ham zaman serisi verilerinden, istatistiksel ve frekans tabanlı ayırt edici özellikler çıkarılmış ve bu özellikler, Rastgele Orman, XGBoost ve Destek Vektör Makineleri gibi standart makine öğrenmesi modelleriyle sınıflandırılmıştır. Deneysel sonuçlar, topluluk tabanlı modellerin olağanüstü bir performans sergilediğini ortaya koymuştur. XGBoost ve Rastgele Orman modelleri, test seti üzerinde sırasıyla %99 ve %98'lik doğruluk ve F1-skorlarına ulaşarak, çıkarılan özelliklerin farklı ağrı durumlarını ayırt etmede son derece etkili olduğunu kanıtlanmıştır. Bu yüksek başarı, daha karmaşık derin öğrenme mimarilerine olan ihtiyacı ortadan kaldırmıştır. Sonuç olarak, bu çalışma, etkili bir özellik mühendisliği süreci ve standart makine öğrenmesi algoritmaları ile fizyolojik sinyallerden akut ağrı tiplerinin neredeyse mükemmel bir doğrulukla tespit edilebileceğini göstermektedir. Bu sonuçlar, giyilebilir teknolojilerin ağrıyı cerrahi işlem gerektirmeden, güvenli ve objektif şekilde izlemek için etkili bir klinik araç olabileceğini desteklemektedir.

Anahtar Kelimeler: Ağrı değerlendirmesi, makine öğrenmesi, fizyolojik sinyaller, sinyal işleme, giyilebilir sensörler

Detection of Acute Pain with Multimodal Biosignals Using Machine Learning

Research Article

Received

07/07/2025

Accepted

07/08/2025

DOI

[10.70562/tubid.1736747](https://doi.org/10.70562/tubid.1736747)

Abstract

The subjective nature of pain necessitates the development of objective assessment methods. This study investigates the feasibility and efficacy of automatically classifying different types of acute pain using multimodal physiological signals obtained from wearable sensors. Physiological data (BVP, EDA, ACC, TEMP) from 99 participants, encompassing headache, back pain, menstrual pain, and pain-free states, were analyzed using the publicly available "PhysioPain Dataset." Discriminative statistical and frequency-based features were extracted from raw time-series data and classified using standard machine learning models, including Random Forest, XGBoost, and Support Vector Machines. Experimental results demonstrate that ensemble-based models exhibited exceptional performance. Specifically, XGBoost and Random Forest achieved accuracy and F1-scores of 99% and 98%, respectively, on the test set, confirming the high effectiveness of the extracted features in distinguishing various pain states. This superior performance eliminates the need for more complex deep learning architectures. In conclusion, this study demonstrates that acute pain types can be detected with near-perfect accuracy through effective feature engineering and standard machine learning algorithms applied to physiological signals. These findings reinforce the potential of wearable technologies as reliable clinical tools for the objective, automated, and non-invasive monitoring of pain.

Keywords: Pain assessment, machine learning, physiological signals, signal processing, wearable sensors

1. Giriş

Ağrı, bireylerin yaşam kalitesini önemli ölçüde etkileyen karmaşık ve öznel bir deneyimdir ve klinik değerlendirme ile yönetiminde önemli zorluklar yaratır (1). Ağrı türlerinin ve şiddetinin doğru bir şekilde tespit edilmesi, özellikle sırt ağrısı, baş ağrısı ve adet ağrısı gibi kronik durumlarda etkili tanı ve kişiselleştirilmiş tedavi için kritik öneme sahiptir (2). Geleneksel ağrı değerlendirme yöntemleri, Wong-Baker Yüzler Ağrı Ölçeği gibi öznel bildirimlere dayanır ve bireyler arasındaki farklılıklar nedeniyle sınırlılıklar taşır (3). Son yıllarda, giyilebilir sensör teknolojilerindeki gelişmeler ve makine öğrenmesi yöntemleri, fizyolojik sinyaller aracılığıyla objektif ağrı değerlendirmesi için yeni olanaklar sunmaktadır (4).

Ağrı, insan yaşamının en temel duyuşsal deneyimlerinden biridir ve genellikle hem bireysel hem de toplumsal düzeyde önemli sonuçlara yol açabilecek fizyolojik ya da patolojik süreçlerin ilk habercisidir. Dünya Sağlık Örgütü'ne (WHO) bağlı Uluslararası Ağrı Araştırmaları Derneği (IASP), ağrıyı "gerçek veya potansiyel doku hasarıyla ilişkili ya da bu hasar gibi algılanan hoş olmayan duyuşsal ve duygusal bir deneyim" olarak tanımlamaktadır (5). Bu tanım, ağrının yalnızca fizyolojik değil aynı zamanda psikososyal ve bilişsel bileşenleri olan çok boyutlu bir olgu olduğunu ortaya koyar.

Ağrı, Uluslararası Ağrı Araştırmaları Derneği (IASP) tarafından güncellenen tanımıyla, "gerçek veya potansiyel bir doku hasarıyla ilişkili veya bu hasarı andıran, hoş olmayan bir duyuşsal ve duygusal deneyim" olarak kabul edilmektedir (5). Bu tanım, ağrının sadece fiziksel bir duyum olmadığını, aynı zamanda bireyin bilişsel ve duygusal durumundan derinden etkilenen karmaşık ve çok boyutlu bir olgu olduğunu vurgulamaktadır. Ağrı deneyiminin bu subjektif doğası, onun değerlendirilmesini ve yönetimini tıp alanındaki en temel zorluklardan biri haline getirmektedir. Klinik pratikte altın standart olarak kabul edilen hastanın kendi beyanına dayalı ağrı ölçekleri (örneğin, Sayısal Değerlendirme Ölçeği - NRS veya Görsel Analog Skala - VAS), hastanın iletişim kurabildiği durumlarda etkili olsa da, bu yeteneğe sahip olmayan popülasyonlarda yetersiz kalmaktadır. Özellikle yeni doğanlar, bilişsel bozukluğu olan yaşlılar, afazi veya felç nedeniyle konuşma yetisini yitirmiş hastalar ve yoğun bakım ünitelerinde sedasyon altındaki bireyler gibi savunmasız gruplar, ağrılarını etkili bir şekilde bildiremezler (6, 7). Bu durum, ağrının tespit edilememesine, yetersiz tedaviye, kronikleşme riskinin artmasına ve hastaların yaşam kalitesinde ciddi düşümlere yol açmaktadır. Bu klinik zorluğun üstesinden gelmek amacıyla, son yıllarda ağrıyı nesnel (objektif) biyobelirteçler aracılığıyla değerlendirebilen teknolojilere yönelik ilgi artmıştır. Ağrı, otonom sinir sistemini (OSS) aktive ederek bir dizi ölçülebilir fizyolojik değişikliğe neden olur. Bu değişiklikler arasında kalp atış hızındaki (HR) ve kalp atış hızı değişkenliğindeki (HRV) dalgalanmalar, derinin elektriksel iletkenliğindeki (elektrodermal aktivite - EDA) artışlar, periferik kan akışındaki değişimler ve vücut sıcaklığındaki dalgalanmalar yer almaktadır (8). Giyilebilir sensör teknolojilerindeki (örneğin, akıllı bileklikler) hızlı ilerlemeler, bu fizyolojik sinyallerin (fotopletismografi - PPG, kan hacmi pulsu - BVP, ivmeölçer - ACC, vücut sıcaklığı - TEMP) sürekli ve non-invaziv bir şekilde izlenmesini mümkün kılmıştır. Bu sinyaller, ağrının varlığına ve

yoğunluğuna dair değerli ve objektif veriler sunarak, hastanın sözel beyanına olan bağımlılığı azaltma potansiyeli taşımaktadır (9).

Fizyolojik verilerin karmaşıklığı ve bireyler arası değişkenliği, bu sinyalleri anlamlandırmak için gelişmiş analitik yöntemler gerektirmektedir. Bu noktada yapay zekâ ve özellikle derin öğrenme, zaman serisi şeklindeki çok modlu biyosinyal verilerinden anlamlı örüntüler çıkarmak için güçlü araçlar sunmaktadır. Literatürde, ağrı tespiti için derin öğrenme modellerinin kullanıldığı çeşitli çalışmalar bulunmaktadır. Bu çalışmalar genellikle görsel veriler (yüz ifadeleri) veya fizyolojik sinyaller üzerine yoğunlaşmıştır. Örneğin, UNBC-McMaster Omuz Ağrısı ifadesi veri seti gibi kaynaklar kullanılarak geliştirilen modeller, ağrıya özgü yüz kasılmalarını ve ifadelerini yüksek doğrulukla tanıyabilmektedir (10, 11). Fizyolojik sinyal tabanlı yaklaşımlar ise daha çok OSS tepkilerine odaklanmıştır. Subramanian ve arkadaşları (2023), postoperatif hastalarda EKG ve EDA sinyallerini birleştirerek ağrıyı tanımlamış (12), Phan ve arkadaşları (2023) ise EDA, EKG ve EMG gibi çoklu sinyalleri entegre ederek (veri füzyonu) ağrı tanıma performansını önemli ölçüde artırmıştır (13). Bu çalışmalar, ağrı gibi karmaşık bir olgunun tek bir veri kaynağından ziyade, çoklu veri kaynaklarının birleştirilmesiyle daha sağlam ve güvenilir bir şekilde anlaşılabilirliğini göstermektedir.

Ağrının nesnel olarak izlenmesi, özellikle kronik ağrının temel bir bileşen olduğu romatolojik hastalıklarda büyük önem taşımaktadır (14). Bu hastalıklar arasında, çocukluk çağında en sık görülen kronik romatizmal hastalıklardan biri olan Jüvenil İdiyopatik Artrit (JIA) öne çıkmaktadır (15). JIA'lı çocuklar, sürekli veya alevlenmelerle seyreden eklem ağrısı ve şişliği yaşarlar. Yetişkinlerin aksine, çocuklar ağrıların yoğunluğunu, karakterini ve yerini doğru bir şekilde ifade etmekte zorlanabilirler. Bu durum, hastalığın aktivitesinin ve tedaviye yanıtın değerlendirilmesini güçleştirir. Yönetilemeyen kronik ağrı, çocukların fiziksel fonksiyonlarını (örneğin yürüme, oyun oynama), okul başarılarını ve psikososyal gelişimlerini olumsuz yönde etkileyebilir. Bu nedenle, pediatrik romatoloji hastalarında ağrıyı nesnel olarak izleyebilen bir sistem, klinisyenlere tedavi kararlarında değerli bir destek sağlayabilir ve hastaların uzun vadeli sağlık sonuçlarını iyileştirebilir.

Empatica E4 gibi giyilebilir cihazlar, Elektrodermal Aktivite (EDA), Kan Hacmi Nabızı (BVP), İvmeölçer (ACC) ve Sıcaklık (TEMP) gibi çok modlu biyosinyalleri toplama imkânı sağlar ve ağrı ile ilişkili fizyolojik tepkiler hakkında bilgi sunar (16). Bu sinyaller, otonom sinir sistemi aktivitelerini ve fiziksel hareketleri yansıtır; örneğin, EDA sempatik sinir sistemi aktivasyonunu, BVP ise kalp atış hızı değişkenliğini gösterir ve her ikisi de ağrı şiddeti ve türüyle ilişkilendirilmiştir (17, 18). İvmeölçer verileri, ağrı kaynaklı hareket değişikliklerini ortaya koyabilir (19), sıcaklık değişimleri ise stres tepkilerini işaret edebilir (20).

Makine öğrenmesi, özellikle derin öğrenme yaklaşımları, çok modlu biyosinyalleri analiz ederek ağrı sınıflandırmasında umut verici sonuçlar göstermiştir. Evrişimli Sinir Ağları (CNN) (34-38) ve Uzun Kısa Süreli Bellek (LSTM) modelleri, fizyolojik sinyallerden zamansal ve frekans domeni özelliklerini çıkarmak için yaygın olarak kullanılmaktadır (21, 22). Örneğin, (21), EDA ve BVP özelliklerini birleştiren bir CNN tabanlı mimari ile ağrı tespitinde başarılı sonuçlar elde etmiştir. Benzer

şekilde, (22), LSTM modellerinin zamansal bağımlılıkları yakalamadaki etkinliğini göstermiştir. Bununla birlikte, çok modlu veri entegrasyonu, sınıf dengesizlikleri ve farklı ağrı türleri ile popülasyonlara genelleştirme gibi zorluklar devam etmektedir (23).

Bu çalışma, Kaggle platformunda açık erişim olarak sunulan PhysioPain Dataset'ini kullanmaktadır. Bu veri seti, farklı ağrı türlerini (ağrı yok, sırt ağrısı, baş ağrısı, adet ağrısı) yaşayan bireylerden toplanan çok modlu biyosinyalleri (EDA, BVP, ACC, TEMP) içerir (24). Veri seti, zaman domeni (ortalama, varyans, minimum/maksimum) ve frekans domeni (Hızlı Fourier Dönüşümü katsayıları) özelliklerini çıkarmak için işlenmiştir. Bu çalışma, çok modlu biyosinyal entegrasyonuna dayalı bir model olan Fizyolojik Füzyon Sınıflayıcısını önermektedir. Bu model, zaman, frekans ve hareket özelliklerini birleştiren çok girişli bir 1D-CNN mimarisi kullanır. Ayrıca, önerilen modelin performansı, geleneksel makine öğrenmesi yöntemleri (Random Forest, Destek Vektör Makineleri, XGBoost) ve bağımsız bir 1D-CNN modeli ile karşılaştırılmıştır.

Bu çalışmanın temel katkısı, ağrı türlerinin sınıflandırılmasına yönelik olarak çok modlu biyosinyal entegrasyonuna dayalı Fizyolojik Füzyon Sınıflayıcısı'nın geliştirilmesi ve kapsamlı bir şekilde değerlendirilmesidir. Açık erişimli bir veri seti ve sağlam özellik çıkarma teknikleri kullanılarak, bu çalışma objektif ağrı değerlendirmesi alanında ilerlemeyi amaçlamakta ve klinik tanı ile kişiselleştirilmiş ağrı yönetimi için potansiyel uygulamalar sunmaktadır. Makalenin geri kalanı şu şekilde organize edilmiştir: Bölüm 2'de literatür araştırması, Bölüm 3'te materyal ve metot, Bölüm 4'te deneysel sonuçlar, Bölüm 5'te ise bulguların literatür bağlamında tartışılması ve gelecekteki araştırma yönleri sunulmaktadır.

1.1. Literatür

Ağrının nesnel olarak değerlendirilmesi, son yirmi yılda mühendislik ve tıp bilimlerinin kesişiminde önemli bir araştırma alanı olarak öne çıkmıştır. Bu alandaki çalışmalar, ağrının dışavurumlarını yakalamak için temelde iki ana veri türüne odaklanmıştır: davranışsal/görsel ipuçları ve fizyolojik sinyaller.

Ağrı araştırmalarındaki ilk nesnel yaklaşımlar, ağrının yüz ifadelerinde yarattığı istemsiz kasılmaları analiz etmeye dayanmaktadır. Bu alandaki ilerlemeler, ağrıya özgü yüz ifadelerini içeren standartlaştırılmış veri setlerinin oluşturulmasıyla hız kazanmıştır. (10) tarafından geliştirilen UNBC-McMaster Omuz Ağrısı İfadesi veri seti, bu alandaki temel kaynaklardan biri olup, omuz ağrısı yaşayan bireylerin yüz hareketlerini (Action Units - AU) detaylı bir şekilde etiketlemiştir. Bu tür veri setleri, derin öğrenme modellerinin geliştirilmesi için bir zemin hazırlamıştır. Örneğin, Rodriguez ve ark. (25), Uzun Kısa Süreli Bellek (LSTM) ağlarını kullanarak yüz ifadelerindeki zamansal dinamikleri analiz etmiş ve ağrıyı yüksek doğrulukla sınıflandıran "Deep Pain" modelini sunmuştur. Benzer şekilde, yenidoğan popülasyonu gibi sözel iletişimin imkansız olduğu gruplarda da görsel analiz kritik bir rol oynamaktadır. Brahnam ve ark. (26) tarafından yürütülen çalışma, topuk kanı alımı gibi ağrılı prosedürler sırasında kaydedilen yenidoğan videolarını kullanarak, bu savunmasız grupta ağrı varlığını

tespit etmeyi amaçlayan modeller geliştirmiştir. Ancak, yüz ifadelerinin bireyin iradesi veya kültürel faktörler tarafından baskılanabilmesi, bu yöntemin tek başına kullanımının sınırlılıklarını ortaya koymaktadır.

Görsel ipuçlarının sınırlılıklarını aşmak amacıyla araştırmalar, ağrıya yanıt olarak otonom sinir sisteminde (OSS) meydana gelen istemsiz fizyolojik değişikliklere yönelmiştir. Ağrı, OSS'nin sempatik dalını aktive ederek kalp atış hızı (HR), kalp atış hızı değişkenliği (HRV), solunum hızı (RR) ve özellikle derinin elektriksel iletkenliği (elektrodermal aktivite - EDA) gibi bir dizi ölçülebilir parametrede değişikliğe neden olur. Walter ve ark. (9) tarafından oluşturulan BioVid Isı Ağrısı Veri Seti, kontrollü koşullar altında katılımcılara uygulanan ısı ağrısına karşı kaydedilen EKG, EMG ve EDA gibi sinyalleri içererek bu alandaki araştırmalar için temel bir kaynak sağlamıştır.

Başlangıçta çalışmalar, tek bir sinyalin ağrı tespiti için ne kadar güçlü bir biyobelirteç olduğunu araştırmıştır. Örneğin Pinzon-Arenas ve ark. (27), sadece fazik EDA verilerini kullanarak sürekli akut ağrı tespiti için derin öğrenme modelleri tasarlamış ve EDA'nın ağrı yoğunluğuyla güçlü bir korelasyon gösterdiğini kanıtlamıştır.

Ağrının çok boyutlu doğası, tek bir sinyalin ağrının tüm karmaşıklığını yakalamada yetersiz kalabileceğini göstermiştir. Bu nedenle, son yıllardaki en belirgin eğilim, birden çok fizyolojik sinyalin birleştirildiği (çok modlu füzyon) yaklaşımlardır. Bu yöntem, farklı sinyallerden gelen tamamlayıcı bilgileri birleştirerek daha sağlam ve güvenilir bir sınıflandırma performansı sunmayı hedefler. Subramanian ve ark. (28), postoperatif hastalarda ağrıyı tanımak için EKG, EDA, EMG ve RR sinyallerini bir makine öğrenmesi modeliyle birleştirmiş ve füzyon yaklaşımının etkinliğini göstermiştir. Daha ileri bir çalışma olan Phan ve ark. (13), EDA, EKG ve EMG verilerini birleştiren çok seviyeli bağlam bilgisi (multi-level context information) içeren bir model sunarak, sinyaller arasındaki karmaşık ilişkileri yakalamanın ağrı tanıma doğruluğunu önemli ölçüde artırdığını ortaya koymuştur.

Bu teknolojilerin en kritik uygulama alanlarından biri, ağrı değerlendirmesinin özellikle zor olduğu pediatrik popülasyondur. Ajayi ve ark. (8) tarafından yapılan çalışma, giyilebilir sensörler aracılığıyla ciddi hastalıkları olan çocuklarda biyofiziksel belirteçlerin toplanabileceğini ve bu verilerin ağrı takibinde kullanılabileceğini göstermiştir.

Bu çalışma, teknolojinin klinikteki potansiyelini vurgulamakla birlikte, spesifik hastalık gruplarına yönelik çalışmaların eksikliğine de işaret etmektedir.

Bu literatür bağlamında, Yıldırım (29) tarafından yürütülen tez çalışması, önemli ve özgün bir katkı sunmaktadır. Literatürdeki çalışmaların büyük bir kısmı yetişkinlere veya genel akut ağrı senaryolarına odaklanırken, bu tez, daha önce yeterince çalışılmamış, spesifik bir grup olan pediatrik romatoloji hastalarında kronik ağrının objektif tespitini hedeflemiştir. Çalışma, EDA, kan hacmi pulsü (BVP), ivmeölçer (ACC) ve vücut sıcaklığı (TEMP) gibi çok modlu biyosinyalleri, hastaların Wong-Baker Yüzler Ağrı Ölçeği ile bildirdiği subjektif ağrı skorlarıyla birleştirerek, literatürdeki füzyon yaklaşımlarını, zorlu bir klinik probleme uygulamaktadır. Bu yaklaşım, literatürdeki boşluğu doldurarak

hem pediatrik ağrı yönetimi için yeni bir yol önermekte hem de bu spesifik popülasyon için değerli bir veri seti ve modelleme çerçevesi sunmaktadır.

2. Materyal ve metod

Bu çalışma, akut ağrı tiplerini nesnel olarak sınıflandırmak için çok modlu bir fizyolojik veri setini ve bu veri seti üzerinde eğitilmiş makine öğrenmesi ve derin öğrenme modellerini içermektedir.

2.1. Materyal: Physiopain veri seti

Bu çalışmada, İstanbul Kültür Üniversitesi tarafından oluşturulan ve Kaggle platformunda açık erişime sunulan PhysioPain veri seti (24) kullanılmıştır. Söz konusu veri seti, ağrının öznel doğasına karşın, fizyolojik sinyallerle desteklenen bir sistem aracılığıyla nesnel olarak değerlendirilebileceği yönündeki hipotezi test etmek amacıyla geliştirilmiştir.

2.2. Katılımcılar ve ağrı tipleri

Veri seti, 99 sağlıklı katılımcıdan toplanan verileri içermektedir. Katılımcılardan, yaygın olarak karşılaşılan üç farklı akut ağrı türünü deneyimledikleri veya ağrısız oldukları durumlar için veri toplanması istenmiştir. Sınıflandırılan ağrı durumları şunlardır:

- Baş ağrısı
- Sırt ağrısı
- Menstrüel ağrı
- Ağrısız durum (kontrol grubu)

Bu yapı, modelin sadece ağrının varlığını değil, aynı zamanda farklı ağrı tiplerini de ayırt etme yeteneğini ölçmek için tasarlanmıştır.

2.3. Veri toplama cihazları ve sinyaller

Veri toplama süreci, iki farklı giyilebilir sensör kullanılarak gerçekleştirilmiştir:

Empatica E4 Bilekliği: Bu cihaz, bilekten giyilen ve otonom sinir sistemi yanıtlarını ölçen çok modlu bir sensördür. Toplanan sinyaller şunları içerir:

- Kan Hacmi Pulsu (BVP): Fotopletismografi (PPG) sensörü ile elde edilen ve kalp atış hızı ile ilgili bilgiler içeren sinyal.
- Elektrodermal Aktivite (EDA): Derinin elektriksel iletkenliğindeki değişimleri ölçerek sem patik sinir sistemi aktivitesini yansıtan sinyal.
- Vücut Sıcaklığı (TEMP): Cildin yüzey sıcaklığını ölçen sinyal.
- İvmeölçer (ACC): Üç eksenli (X, Y, Z) hareket verilerini kaydeden sensör.

2.4. Veri yapısı

Veri seti, her katılımcı için benzersiz bir kimlik (ID) ile yapılandırılmıştır. Her katılımcının ve ağrı durumunun verileri, farklı örnekleme frekanslarında ('4 Hz', '8 Hz', '16 Hz', '32 Hz') işlenmiş

CSV dosyaları olarak saklanmaktadır. Bu yapı, modellerin farklı zaman çözünürlüklerindeki performansını test etme olanağı tanır. Ayrıca, katılımcıların demografik bilgileri ve McGill Ağrı Anketi (30) gibi standart ağrı ölçeklerine verdikleri yanıtları içeren anket verileri de mevcuttur.

2.5. Metot

Bu çalışmada izlenen metodoloji; ham sinyal verilerinden anlamlı bilgilerin çıkarılmasını, bu bilgilerin makine öğrenmesi ve derin öğrenme modelleri ile işlenmesini ve modellerin performansının kıyaslanmasını kapsar. Tüm analizler Python programlama dili ve ‘Scikit-learn’, ‘TensorFlow/Keras’ gibi kütüphaneler kullanılarak gerçekleştirilmiştir.

2.6. Veri ön işleme ve özellik çıkarma

Zaman domeni özellikleri (ortalama, varyans, minimum, maksimum), sinyalin temel istatistiksel karakteristiklerini tanımlayarak bireyin fizyolojik durumundaki değişimleri yansıtır. Örneğin, EDA sinyalinin ortalaması sempatik sinir sistemi aktivitesini gösterirken, BVP’nin varyansı kardiyovasküler dalgalanmaları temsil eder. Frekans domeni özellikleri ise özellikle ağrı gibi fizyolojik durumların otonom sinir sistemi üzerindeki etkilerini frekans bileşenleri üzerinden ortaya koymak için kullanılır. FFT ile elde edilen baskın frekans bileşenleri, literatürde sıkça tercih edilen ve sinyallerdeki düzenlilik/karmaşıklık düzeyini yansıtan bir göstergedir. Bu özelliklerin her biri, önceki çalışmalarda fizyolojik sinyallerle ağrı, stres, duygu durumu gibi durumların sınıflandırılmasında başarıyla kullanılmıştır (13, 17, 21, 23). Bu nedenle seçilen özellik seti, hem ilgili literatürle uyumlu hem de sinyallerin fizyolojik doğasına uygun olarak belirlenmiştir.

Ham zaman serisi verileri, doğrudan modellere girdi olarak sunulmadan önce bir dizi ön işleme ve özellik çıkarma adımından geçirilmiştir. Bu süreç, ham sinyallerin gürültüsünü azaltmayı ve sınıflandırma için ayırt edici olan istatistiksel ve frekans tabanlı bilgileri elde etmeyi amaçlamaktadır.

1. Pencereleme (Windowing): Sürekli sinyal verileri, sabit boyutlu, birbiriyle örtüşmeyen pencerelere bölünmüştür. Pencere boyutu, sinyalin örnekleme frekansına (‘4’, ‘8’, ‘16’ veya ‘32 Hz’) eşit olacak şekilde dinamik olarak ayarlanmıştır. Bu, her bir pencerenin tam olarak bir saniyelik sinyal verisini temsil etmesini sağlar.

2. Özellik Çıkarma: Her bir pencereden hem zaman domeninde hem de frekans domeninde olmak üzere çeşitli özellikler çıkarılmıştır. Bu özellikler, sinyallerin merkezi eğilim, dağılım ve periyodik doğası hakkında bilgi içerir:

- Zaman Domeni Özellikleri: Her sinyal (BVP, EDA, ACC eksenleri, TEMP) için ortalama (‘mean’), varyans (‘var’), minimum (‘min’) ve maksimum (‘max’) değerler hesaplanmıştır. Bu özellikler, pencere içindeki sinyal seviyesi ve değişkenliği hakkında temel istatistiksel bilgiler sunar.

- Frekans Domeni Özellikleri: BVP ve EDA sinyalleri için Hızlı Fourier Dönüşümü (FFT) uygulanmıştır. Bu dönüşüm sonucunda elde edilen frekans spektrumundan, en yüksek genliğe

sahip olan baskın frekans bileşeninin genliği ('fft_dominant_amplitude') bir özellik olarak çıkarılmıştır. Bu, sinyaldeki en güçlü periyodik patterni yakalamayı hedefler.

Bu süreç sonunda, her bir saniyelik veri penceresi, 18 adet çıkarılmış özellik içeren tek bir satıra dönüştürülmüştür. Bu çalışmada çıkarılan tüm özelliklerin sinyal bazlı özetine ve bu özelliklerin analiz alanlarına ilişkin bilgiler Tablo 1'te sunulmuştur.

Tablo 1. Her bir sinyal kanalından çıkarılan özelliklerin adı, tanımı ve ait olduğu analiz domeni

Özellik Adı	Sinyal Türü	Açıklama	Alan (Domen)
BVP_mean	BVP	Kalp atımına ilişkin ortalama kan hacmi puls değeri	Zaman
BVP_var	BVP	Kalp atım sinyalinin varyansı; kardiyovasküler değişkenliği gösterir	Zaman
BVP_min	BVP	Pencere içindeki minimum BVP değeri	Zaman
BVP_max	BVP	Pencere içindeki maksimum BVP değeri	Zaman
BVP_fft	BVP	Frekans spektrumunda baskın bileşenin genliği; ritmik aktivite göstergesi	Frekans
EDA_mean	EDA	Cilt iletkenliğinin ortalama değeri; sempatik aktivitenin genel seviyesi	Zaman
EDA_var	EDA	Cilt iletkenliğindeki varyasyonlar; duygusal/termal tepkilerin göstergesi	Zaman
EDA_min	EDA	En düşük EDA değeri; bazal sempatik durum göstergesi	Zaman
EDA_max	EDA	En yüksek EDA değeri; ani uyarılma/reaksiyon seviyesi	Zaman
EDA_fft	EDA	EDA frekans spektrumunda baskın frekans genliği	Frekans
ACCx_mean	ACC (X)	X-eksenindeki ortalama ivme değeri	Zaman
ACCx_var	ACC (X)	X-ekseninde hareket yoğunluğu göstergesi	Zaman
ACCy_mean	ACC (Y)	Y-eksenindeki ortalama ivme değeri	Zaman
ACCy_var	ACC (Y)	Y-ekseninde hareket değişkenliği	Zaman
ACCz_mean	ACC (Z)	Z-ekseninde ortalama ivme	Zaman
ACCz_var	ACC (Z)	Z-eksenindeki hareketlilik derecesi	Zaman
TEMP_mean	Sıcaklık (TEMP)	Ortalama cilt sıcaklığı; stres ve ağrı ile ilişkili olabilir	Zaman
TEMP_var	Sıcaklık (TEMP)	Sıcaklıktaki dalgalanma miktarı; termoregülasyon aktivitesi göstergesi	Zaman

3. Veri Birleştirme ve Etiketleme: Tüm frekanslardan ve ağrı sınıflarından elde edilen özellik setleri tek bir veri çerçevesinde birleştirilmiştir. 'no_pain', 'back_pain', 'headache' ve 'menstrual_pain' sınıfları sırasıyla 0, 1, 2 ve 3 olarak sayısal etiketlere dönüştürülmüştür.

4. Standardizasyon: Çıkarılan özelliklerin farklı ölçeklerde olması, bazı modellerin performansını olumsuz etkileyebilir. Bu nedenle, tüm özellikler, eğitim setinin ortalamasını 0 ve standart sapmasını 1 yapacak şekilde 'StandardScaler' kullanılarak standardize edilmiştir. Aynı ölçeklendirme dönüşümü, validasyon ve test setlerine de uygulanmıştır.

2.7. Modelleme yaklaşımları

Özellik setinin sınıflandırılması için, hem literatürde yaygın olarak kullanılan geleneksel makine öğrenmesi modelleri hem de özellikler arasındaki karmaşık ve hiyerarşik ilişkileri yakalama potansiyeli taşıyan derin öğrenme yaklaşımlarını içeren kapsamlı bir metodoloji planlanmıştır.

1. Temel Sınıflandırıcılar (Baseline Models): Özellik mühendisliği adımının etkinliğini ölçmek ve bir temel performans çizgisi oluşturmak amacıyla, endüstride ve akademide kanıtlanmış üç güçlü makine öğrenmesi modeli kullanılmıştır:

- Rastgele Orman (Random Forest Classifier): Karar ağaçlarından oluşan ve aşırı öğrenmeye karşı dirençli bir topluluk öğrenmesi modelidir.
- Destek Vektör Makineleri (Support Vector Classifier - SVC): Veri noktaları arasında en geniş marjini bulan bir hiper-düzlem oluşturarak sınıflandırma yapan bir modeldir.
- XGBoost (eXtreme Gradient Boosting): Karar ağaçlarını aşamalı olarak iyileştiren, yüksek performanslı bir gradyan artırma (gradient boosting) algoritmasıdır.

2. İleri Modelleme Hipotezi ve Gözlemler: Başlangıç hipotezimiz, fizyolojik sinyallerden türetilen özellikler arasındaki doğrusal olmayan ve karmaşık ilişkileri yakalamak için derin öğrenme modellerinin (özellikle 1D-CNN ve çok modlu füzyon mimarilerinin) geleneksel modellere göre bir performans artışı sağlayabileceği yönündeydi. Bu doğrultuda, özellik gruplarını ayrı ayrı işleyip birleştiren bir füzyon mimarisi de tasarlanmıştır.

Ancak, temel sınıflandırıcılarla yapılan ilk deneyler, özellikle Rastgele Orman ve XGBoost modellerinin test seti üzerinde %99'un üzerinde doğruluk oranlarına ulaştığını göstermiştir. Bu ezici başarı, iki önemli çıkarımı beraberinde getirmiştir:

- Veri ön işleme ve özellik çıkarma adımları, ham sinyallerdeki ayırt edici bilgiyi o kadar etkili bir şekilde yakalamıştır ki, bu özellikler geleneksel modeller tarafından kolayca ayrılabilir hale gelmiştir.
- Geleneksel modellerin ulaştığı bu neredeyse mükemmel performans seviyesi, daha karmaşık olan derin öğrenme modellerinin sağlayabileceği potansiyel marjinal faydayı anlamsız kılmaktadır. Bu seviyeden sonra anlamlı bir iyileştirme alanı kalmamıştır.

Bu bulgular ışığında, çalışmanın odağı, derin öğrenme modellerinin karmaşık mimarilerini optimize etmek yerine, çıkarılan özelliklerin gücünü ve temel sınıflandırıcıların bu problem üzerindeki etkinliğini göstermeye kaydırılmıştır. Dolayısıyla, nihai sonuçlar ve kıyaslamalar, bu üç temel makine öğrenmesi modeli üzerine odaklanmıştır. Bu yaklaşım, problemin çözümü için her zaman en karmaşık modelin gerekli olmadığını, etkili bir özellik mühendisliğinin daha basit ve yorumlanabilir modellerle dahi üstün sonuçlar verebileceğini göstermesi açısından önemlidir.

2.8. Model eğitimi ve değerlendirme

Veri seti, eğitim (%60), validasyon (%20) ve test (%20) olmak üzere üç parçaya ayrılmıştır. Bu bölme işlemi, kişi bazlı olarak gerçekleştirilmiştir; yani her bir katılımcının tüm sinyal pencereleri yalnızca bir alt sette (eğitim, doğrulama veya test) yer almıştır. Böylece modelin aynı kişiye ait örnekleri hem eğitim hem de test aşamasında görmesi engellenmiş ve potansiyel veri sızıntısının önüne geçilmiştir. Derin öğrenme modelleri, 'Adam' optimizasyon algoritması ve 'categorical_crossentropy' kayıp fonksiyonu kullanılarak eğitilmiştir. Aşırı öğrenmeyi (overfitting) engellemek için, validasyon kaybının 5 epok boyunca iyileşmediği durumlarda eğitimi durduran bir 'EarlyStopping' mekanizması kullanılmıştır.

Tüm modellerin performansı, test seti üzerinde standart metrikler kullanılarak değerlendirilmiştir:

- Doğruluk (Accuracy): Doğru tahmin edilen örneklerin toplam örneklere oranı.
- F1-Skoru (F1-Score): Sınıf dengesizliğini dikkate alan, kesinlik (precision) ve duyarlılığın (recall) harmonik ortalaması.
- Karışıklık Matrisi (Confusion Matrix): Modelin hangi sınıfları birbirleriyle karıştırdığını görsel olarak gösteren matris.
- Sınıflandırma Raporu (Classification Report): Her sınıf için kesinlik, duyarlılık ve F1-skorunu detaylı olarak sunan rapor.

Bu metrikler, modellerin genel performansını ve farklı ağırlı tiplerini ne kadar başarıyla ayırt edebildiğini kapsamlı bir şekilde analiz etme imkânı sunar.

3. Deneysel sonuçlar

Bu bölümde, Metot bölümünde açıklanan üç geleneksel makine öğrenmesi modelinin (Rastgele Orman, Destek Vektör Makineleri ve XGBoost) PhysioPain veri setinin test verileri üzerindeki performansı sunulmakta ve değerlendirilmektedir. Modellerin performansı, doğruluk (accuracy), ağırlıklı F1-skoru (weighted F1-score) ve her bir ağırlı sınıfı için elde edilen kesinlik (precision) ve duyarlılık (recall) metrikleri kullanılarak analiz edilmiştir.

3.1. Modellerin genel performans kıyaslaması

Test seti üzerinde yapılan değerlendirmeler sonucunda elde edilen genel performans metrikleri Tablo 2’de özetlenmiştir. Sonuçlar, topluluk tabanlı modeller olan Rastgele Orman ve XGBoost’un, Destek Vektör Makineleri’ne kıyasla ezici bir üstünlük sergilediğini açıkça göstermektedir.

Tablo 2. Modellerin test seti üzerindeki genel performans metrikleri.

Model	Doğruluk (Accuracy %)	F1-Skoru (%)
Rastgele Orman	98	98
XGBoost	99	99
SVM	78	78

Tablo 2’den da görüleceği üzere, XGBoost modeli %99’luk doğruluk ve F1-skoru ile en yüksek performansı sergilemiştir. Rastgele Orman modeli de %98’lik skorlarla XGBoost’a çok yakın bir başarı elde etmiştir. Buna karşın, SVM modeli %78’lik doğruluk ve F1-skoru ile diğer iki modelin önemli ölçüde gerisinde kalmıştır. Bu durum, problemin doğasının ve özellik uzayının, SVM’nin hiper-düzlem tabanlı ayırım mekanizmasından ziyade, karar ağacı tabanlı topluluk modelleri tarafından daha etkili bir şekilde modellendiğini göstermektedir.

3.2. Sınıf bazında detaylı analiz

Modellerin genel performansının yanı sıra, her bir ağırlı tipini ne kadar başarılı bir şekilde sınıflandırdığını anlamak için sınıf bazında elde edilen sonuçlar incelenmiştir.

3.3. Rastgele orman (random forest)

Rastgele Orman modelinin sınıflandırma raporu Tablo 3’de sunulmuştur. Model, özellikle "ağrısız durum" ve "menstrüel ağrı" sınıflarını mükemmel yakın bir performansla (%100 kesinlik ve duyarlılık) sınıflandırmıştır. "Sırt ağrısı" ve "baş ağrısı" sınıflarında ise yine çok yüksek oranlarda (%97 civarında) başarı göstermiştir. Bu sonuçlar, modelin tüm sınıflar arasında dengeli ve yüksek bir performans sergilediğini kanıtlamaktadır.

Tablo 3. Rastgele orman modelinin sınıf bazında performansı.

Sınıf	Kesinlik (Precision %)	Duyarlılık (Recall %)	F1-Skoru %
Ağrısız (no pain)	100	100	100
Sırt Ağrısı (back pain)	98	98	98
Baş Ağrısı (headache)	98	97	98
Menstrüel Ağrı	100	100	100

3.4. XGBoost

En yüksek performansı gösteren XGBoost modelinin detaylı sonuçları Tablo 4’te verilmiştir. Tıpkı Rastgele Orman gibi, XGBoost da "ağrısız durum" ve "menstrüel ağrı" sınıflarını hatasız bir şekilde tanımıştır. "Sırt ağrısı" ve "baş ağrısı" sınıflarındaki performansı ise %98’e ulaşarak Rastgele Orman modelini bir miktar geride bırakmıştır. Bu durum, XGBoost’un gradyan artırma tekniğinin, özellikler arasındaki ince ayrımları yakalamada marjinal de olsa daha etkili olduğunu düşündürmektedir.

Tablo 4. XGBoost modelinin sınıf bazında performansı.

Sınıf	Kesinlik (Precision %)	Duyarlılık (Recall %)	F1-Skoru %
Ağrısız (no pain)	100	100	100
Sırt Ağrısı (back pain)	97	98	97
Baş Ağrısı (headache)	97	97	97
Menstrüel Ağrı	100	100	100

3.5. Destek vektör makineleri (SVM)

SVM modelinin performansı, diğer iki modele kıyasla oldukça düşüktür (Tablo 5). Özellikle "ağrısız durum" sınıfında kesinlik oranının (%69) düşük olması, modelin diğer ağrı türlerini bu sınıfla karıştırdığına işaret etmektedir. En yüksek F1-skorunu (%84) "menstrüel ağrı" sınıfında elde etmiş olsa da genel performansı ve diğer sınıflardaki başarısı, bu problemin çözümü için uygun bir model olmadığını göstermektedir.

Tablo 5. SVM Modelinin Sınıf Bazında Performansı

Sınıf	Kesinlik (Precision %)	Duyarlılık (Recall%)	F1-Skoru %
Ağrısız (no pain)	69	85	76
Sırt Ağrısı (back pain)	89	68	77
Baş Ağrısı (headache)	78	79	79
Menstrüel Ağrı	76	93	84

3.6. Sonuç

Deneyisel bulgular, etkili bir özellik mühendisliği süreciyle fizyolojik sinyallerden akut ağrı türlerinin oldukça yüksek doğrulukla sınıflandırılabilceğini ortaya koymaktadır. Özellikle XGBoost ve Rastgele Orman gibi topluluk tabanlı algoritmaların %98–99 aralığında sınıflandırma başarısına ulaşması, Yöntem bölümünde ortaya konan hipotezi desteklemektedir: Elde edilen istatistiksel ve frekans tabanlı özellikler, farklı ağrı türleri arasında anlamlı ayrımlar yapılmasına olanak tanıyacak düzeyde bilgi taşımaktadır. Bu yüksek performans, daha karmaşık ve hesaplama açısından maliyetli derin öğrenme mimarilerine duyulan gereksinimi ortadan kaldırmakta; bunun yerine, daha sade, yorumlanabilir ve etkin makine öğrenimi yaklaşımlarının tercih edilmesini gerektirmektedir.

4. Tartışma

Bu çalışmada, çok modlu fizyolojik sinyallerden (BVP, EDA, ACC, TEMP) çıkarılan özellikler kullanılarak farklı akut ağrı tiplerinin (baş ağrısı, sırt ağrısı, menstrüel ağrı) ve ağrısız durumun sınıflandırılması hedeflenmiştir. Elde edilen %99'a varan doğruluk oranı, fizyolojik belirteçlerin, ağrının nesnel değerlendirilmesi için ne denli güçlü bir potansiyele sahip olduğunu kanıtlamaktadır. Bu bölüm, elde edilen sonuçların anlamını, literatürdeki yerini, çalışmanın güçlü yönlerini ve sınırlılıklarını tartışmaktadır.

Çalışmanın en dikkat çekici bulgusu, karar ağacı tabanlı topluluk modellerinin (Rastgele Orman ve XG Boost) bu sınıflandırma problemi üzerinde neredeyse mükemmel bir performans sergilemesidir. Bu durum, metodoloji bölümünde detaylandırılan özellik mühendisliği sürecinin başarısını göstermektedir. Ham zaman serisi verilerinden çıkarılan basit istatistiksel (ortalama, varyans) ve temel frekans (baskın genlik) özelliklerinin, farklı ağrı tiplerini ayırt etmek için son derece zengin ve ayırt edici bir bilgi içerdiği anlaşılmaktadır. Literatürdeki birçok çalışma, karmaşık derin öğrenme mimarileri ve uçtan uca öğrenme yaklaşımlarına odaklanırken (13, 25), bu çalışma, iyi yapılandırılmış bir özellik setinin, daha basit, daha hızlı ve daha yorumlanabilir olan geleneksel modellerle dahi üstün sonuçlar verebileceğini ortaya koymaktadır. Bu bulgu, özellikle kaynak kısıtlı ortamlarda veya gerçek zamanlı uygulamalarda, hesaplama maliyeti yüksek derin öğrenme modellerine pratik bir alternatif sunması açısından önemlidir.

SVM modelinin diğer iki modele kıyasla belirgin şekilde düşük performans göstermesi, özellik uzayının doğrusal olarak kolayca ayrılamayan, karmaşık ve örtüşen bölgeler içerdiğini düşündürmektedir. Karar ağacı tabanlı modellerin, özellik uzayını ardışık olarak bölerek bu karmaşık sınırları daha etkin bir şekilde modelleyebilmesi, performans farkının temel nedenini oluşturabilir.

Bu çalışmanın sonuçları, literatürdeki çok modlu ağrı tanıma çalışmalarını destekler niteliktedir. (28) ve (13) gibi çalışmalar, farklı fizyolojik sinyallerin birleştirilmesinin ağrı tanıma doğruluğunu artırdığını göstermiştir. Bizim çalışmamız ise bu füzyon konseptini, özellik çıkarma seviyesinde gerçekleştirerek, farklı sinyal modalitelerinden (otonomik, hareket, termal) gelen bilgilerin

entegrasyonunun, sadece ağrının varlığını değil, aynı zamanda farklı akut ağrı tiplerini de ayırt etmede ne kadar etkili olduğunu göstermiştir.

Bununla birlikte, çalışmanın bazı sınırlılıkları bulunmaktadır. İlk olarak, veri seti akut ağrı durumlarını içermektedir. Elde edilen modellerin kronik ağrı gibi daha uzun süreli ve farklı fizyolojik profillere sahip durumlar üzerindeki performansı bilinmemektedir. İkinci olarak, ağrı etiketleri katılımcıların kendi beyanlarına dayanmaktadır. Ağrı deneyiminin subjektif doğası gereği, bildirilen ağrı tipi ile fizyolojik yanıtlar arasında bireysel farklılıklar olabilir. Son olarak, bu çalışma kontrollü bir veri toplama ortamında gerçekleştirilmiştir; modellerin günlük yaşamın getirdiği gürültülü ve değişken koşullar altındaki performansı (örneğin, fiziksel aktivite veya duygusal stres anları) daha ileri araştırmalar gerektirmektedir.

5. Sonuç ve Öneriler

Bu çalışma, Empatica E4 bilekliği gibi giyilebilir sensörlerden elde edilen çok modlu fizyolojik sinyaller kullanılarak, baş ağrısı, sırt ağrısı ve menstrüel ağrı gibi farklı akut ağrı tiplerinin, ağrısız durumdan yüksek bir doğrulukla ayırt edilebileceğini başarıyla göstermiştir. Etkili bir özellik çıkarma süreci ve Rastgele Orman ile XGBoost gibi topluluk tabanlı makine öğrenmesi modelleri kullanılarak, test seti üzerinde %99'a varan bir sınıflandırma performansı elde edilmiştir. Bu sonuç, ağrının nesnel, otomatik ve non-invaziv olarak değerlendirilmesi için fizyolojik sinyallerin ve makine öğrenmesinin umut vadeden bir araç olduğunu doğrulamaktadır.

Çalışmanın en önemli sonucu, karmaşık derin öğrenme modellerine başvurmadan, iyi tasarlanmış bir özellik seti ile dahi olağanüstü sonuçlar alınabileceğidir. Bu, özellikle klinik uygulamalara ve giyilebilir cihazlara entegre edilecek sistemler için hesaplama verimliliği ve model yorumlanabilirliği açısından büyük bir avantajdır.

Literatür incelemeleri göstermektedir ki, derin öğrenme modelleri (örneğin CNN-LSTM yapıları), geleneksel makine öğrenmesi modellerine kıyasla doğrulukta yaklaşık %7–8 oranında artı değer sağlayabilmektedir. Örneğin, Siddiqui ve ark. (2025) EEG tabanlı uyku sınıflandırmasında CNN-LSTM + dikkat modellerinin %89.7 doğruluğu, Random Forest gibi geleneksel yaklaşımların %82.4 doğruluğunu aşmaktadır; ancak bu artış, çıkarım süresinde yaklaşık %15 oranında uzama demektir (31). Benzer şekilde Afuan ve ark (32) düşme tespitinde CNN %94 doğruluk sağlarken, Random Forest %89 doğrulukla daha kısa işlem süreleri sunmaktadır; SVM ve k-NN daha düşük doğrulukta fakat daha yüksek hız sunmaktadır. Bio-IoT uygulamaları bağlamında yapılan başka bir çalışmada ise, XGBoost (~2.1 ms/sinyal), Random Forest (~3.0 ms/sinyal) en hızlı inferans sürelerine sahip modeller arasında yer alırken, LSTM yaklaşık 7.8 ms/sinyal sürmektedir; hibrit bir CNN tabanlı model olan TANEIA ise ~3.6 ms/sample ile LSTM'den hızlı fakat geleneksel yöntemlerin hâlâ gerisinde kalmaktadır (33). Bu literatür destekli bulgular doğrultusunda, çalışmamızda kullanılan geleneksel model tabanlı yaklaşım, mobil sağlık ve edge-cihaz gibi sınırlı kaynaklı sistemlerde hem yeterli

doğruluk hem de düşük gecikme gerektiren senaryolarda daha pratik ve uygulanabilir bir çözüm sunmaktadır.

Gelecekteki çalışmalar için birkaç önemli yön bulunmaktadır. Öncelikle, bu çalışmada kullanılan metodolojinin, (29) tarafından çalışılan pediatrik romatoloji hastaları gibi farklı ve daha hassas popülasyonlar üzerindeki etkinliği araştırılabilir. İkinci olarak, geliştirilen modellerin, günlük yaşam koşullarında ne kadar sağlam olduğunu test etmek için daha doğal ortamlarda veri toplanması hedeflenmelidir. Ayrıca, önerilen sistemin düşük kaynak tüketimi ve geleneksel öğrenme yöntemlerine dayanması, onu mobil sağlık uygulamaları ve uzaktan hasta izleme sistemleri gibi gerçek zamanlı ve taşınabilir platformlara entegre etmek için elverişli kılmaktadır. Bu senaryolarda, hızlı karar desteği ve düşük gecikme kritik öneme sahiptir. Son olarak, anlık sınıflandırma yerine, ağrının zamansal dinamiklerini (örneğin, ağrının başlangıcı, şiddetlenmesi ve azalması) modelleyebilen, LSTM veya Transformer tabanlı zaman serisi modellerinin, ham sinyal verileri üzerinde uçtan uca eğitilmesi, gelecekteki araştırmalar için potansiyel bir iyileştirme alanı olarak durmaktadır. Nihai hedef, bu teknolojiyi, hastaların yaşam kalitesini artıran ve klinisyenlerin karar verme süreçlerini objektif verilerle destekleyen güvenilir bir klinik araca dönüştürmektir.

Kaynaklar

1. Loeser JD, Treede R-D. The kyoto protocol of IASP basic pain terminology. *Pain*. 2008;137(3):473–7.
2. Breivik H, Collett B, Ventafridda V, Cohen R, Gallacher D. Survey of chronic pain in Europe: Prevalence, impact on daily life, and treatment. *Eur J Pain*. 2006;10(4):287–333.
3. Wong DL, Baker CM. Pain in children: Comparison of assessment scales. *Pediatr Nurs*. 1988;14(1):9–17.
4. Werner P, Al-Hamadi A, Niese R, Walter S, Gruss S, Traue HC. Towards pain monitoring: Facial expression, head pose, a new database, an initial evaluation and a roadmap. *PLoS One*. 2014;9(10):e110188.
5. Raja SN, Carr DB, Cohen M, Finnerup NB, Flor H, Gibson S, et al. The revised international association for the study of pain definition of pain: Concepts, challenges, and compromises. *Pain*. 2020;161(9):1976–82.
6. Brahnam S, Nanni L, McMurtrey S, Lumini A, Brattin R, Slack M, et al. Neonatal pain detection in videos using the ICOPEVID dataset and an ensemble of descriptors extracted from Gaussian of local descriptors. *Appl Comput Inform*. 2023;19(1–2):122–43.
7. Von Baeyer CL. Children's self-reports of pain intensity: scale selection, limitations and interpretation. *Pain Res Manag*. 2006;11(3):157–62.
8. 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;24(4):580–8.

9. Walter S, Gruss S, Ehleiter H, Tan J, Traue HC, Werner P, et al. The BioVid heat pain database: Data for the advancement and systematic validation of an automated pain recognition system. In: 2013 IEEE International Conference on Cybernetics (CYBCO). IEEE; 2013. p. 128–31.
10. Lucey P, Cohn JF, Prkachin KM, Solomon PE, Matthews I. Painful data: The UNBC-McMaster shoulder pain expression archive database. In: 2011 IEEE Int Conf on Automatic Face & Gesture Recognition (FG). IEEE; 2011. p. 57–64.
11. Rodriguez P, Cucurull G, González J, Gonfaus JM, Nasrollahi K, Moeslund TB, et al. Deep pain: Exploiting long short-term memory networks for facial expression classification. *IEEE Trans Cybern.* 2017;52(5):3314–24.
12. Subramanian A, Cao R, Naeini EK, Aqajari SAH, Hughes TD, Calderon M-D, et al. Multimodal pain recognition in postoperative patients: Machine learning approach. *JMIR Form Res.* 2025;9:e67969.
13. Phan KN, Iyortsuun NK, Pant S, Yang HJ, Kim SH. Pain recognition with physiological signals using multi-level context information. *IEEE Access.* 2023;11:20114–27.
14. Cazzola M, Atzeni F, Boccassini L, Cassisi G, Sarzi-Puttini P, et al. Physiopathology of pain in rheumatology. *Reumatismo.* 2014;66(1):4–13.
15. Barut K, Adrovic A, Şahin S, Kasapçopur Ö. Juvenile idiopathic arthritis. *Balkan Med J.* 2017;34(2):90–101.
16. Empatica Inc. Empatica E4 wristband technical specifications [Internet]. 2019 [cited 2025 Jul 30]. Available from: <https://www.empatica.com/research/e4/>
17. Storm H. Changes in skin conductance as a tool to monitor nociceptive stimulation and pain. *Curr Opin Anaesthesiol.* 2002;15(5):609–14.
18. Loggia ML, Mogil JS, Bushnell MC. Empathy hurts: Compassion for another increases both sensory and affective components of pain perception. *Pain.* 2011;152(5):1049–56.
19. Paras M, Rudzinska AK. Motion analysis in pain research. *Pain.* 2009;141(1–2):1–2.
20. Herborn KA, Graves JL, Jerem P, Evans NP. Skin temperature reveals the intensity of acute stress. *Physiol Behav.* 2015;152:225–30.
21. Subramanian R, Wager TD, Mackey S, Reiss AL. Multimodal pain assessment using physiological signals. *J Pain Res.* 2018;11:2237–47.
22. Thiam P, Kessler V, Walter S, Traue HC. Multimodal pain recognition in the context of human-robot interaction. *Front Neurosci.* 2019;13:1034.
23. Werner P, Lopez-Martinez D, Walter S, Al-Hamadi A, Gruss S, Picard RW. Automatic recognition methods supporting pain assessment: A survey. *IEEE Trans Affect Comput.* 2019;13(1):430–48.
24. Orville. Physiopain dataset: A multimodal dataset for pain assessment [Internet]. Kaggle; 2024 [cited 2025 Jul 30]. Available from: <https://www.kaggle.com/datasets/orville/physiopain-dataset>

25. Rodriguez P, Cucurull G, Gonfaus JM, Roca FX, Gonzalez J. Deep pain: Exploiting long short-term memory networks for facial expression classification. *IEEE Trans Cybern.* 2022;52(5):3314–24.
26. Brahnam S, Nanni L, Sexton A, Lumini A. Neonatal pain detection in videos using the ICOPEVID dataset and an ensemble of descriptors extracted from gaussian of local descriptors. *Appl Comput Inform.* 2020 [Preprint].
27. Pinzon-Arenas JO, Kong Y, Chon KH, Posada-Quintero HF. Design and evaluation of deep learning models for continuous acute pain detection based on phasic electrodermal activity. *IEEE J Biomed Health Inform.* 2023;27(9):4250–60.
28. Subramanian A, Ganapathy N, Lázaro J, Perez-Ajates JA, Gil E, Joshi R. Multimodal pain recognition in postoperative patients: A machine learning approach. *bioRxiv* [Preprint]. 2023.
29. Yıldırım E. Objektif ağrı değerlendirmesi için çok boyutlu biyosinyal füzyonu. 2024.
30. Melzack R. The McGill pain questionnaire: Major properties and scoring methods. *Pain.* 1975;1(3):277–99.
31. Siddiqui MIH, Sakib AH, Akter S, Debnath J, Mahmud MR. Comparative analysis of traditional machine learning vs deep learning for sleep stage classification. *Int J Sci Res Arch.* 2025;1778–89.
32. Afuan L, Isnanto RR. A comparative study of machine learning algorithms for fall detection in technology-based healthcare system: Analyzing SVM, KNN, decision tree, random forest, LSTM, and CNN. *E3S Web Conf.* 2025;605:03051.
33. Chandragandhi S, Arvind C, Srihari K. Advanced predictive disease modeling in biomedical IoT using the temporal adaptive neural evolutionary algorithm. *Sci Rep.* 2025;15:20378.
34. Kılıç Ş. HybridVisionNet: An advanced hybrid deep learning framework for automated multi-class ocular disease diagnosis using fundus imaging. *Ain Shams Eng J.* 2025;16(10):103594.
35. Kılıç Ş. Attention-based dual-path deep learning for blood cell image classification using ConvNeXt and Swin Transformer. *J Imaging Inform Med.* 2025;1–19.
36. Çelik Y. Bellek tabanlı LSTM ve GRU makine öğrenmesi algoritmaları kullanarak BIST100 endeks tahmini. *Fırat Üniv Müh Bilim Derg.* 2024;36(2):553–61.
37. Celik Y, Karabatak M. Extracting low dimensional representations from large size whole slide images using deep convolutional autoencoders. *Expert Syst.* 2023;40(4):e12819.
38. Kılıç Ş, Doğan, Y. Deep learning based gender identification using ear images. *Traitement du Signal,* 20223;40(4).