



## Parkinson hastalarının aktivitelerinin tanınmasında TinyML tabanlı uç bilişim sistemi

### TinyML-based edge information system for recognizing the activities of parkinson patients

Mine Boz<sup>1,\*</sup> , Yeliz Durgun<sup>2</sup> 

<sup>1</sup> Tokat Gaziosmanpaşa Üniversitesi, Biyomühendislik Bölümü, 60100, Tokat, Türkiye

<sup>2</sup> Tokat Gaziosmanpaşa University, Biomedical Device Technology Program, 60100, Tokat, Turkey

#### Öz

Parkinson hastalığı, insan sağlığını tehdit eden titremenin ana semptom olduğu nörodejeneratif bir hastalıktır. Günümüzdeki araştırmalar, Parkinson Hastalığının önceden tahmin edilebilmesine, tespit edilebilmesine veya sınıflandırılabilmesine odaklanmaktadır. Son yıllarda çeşitli sensörler kullanılarak giyilebilir hareket algılama sistemleri oluşturulmaya başlanmıştır. Raporlanan sonuçlar; sorunların hemen hemen çözüldüğü izlenimini verirken, dikkate alınan verilerin temsil kapasitesi ve buna bağlı olarak performans değerlendirilmesinin güvenilirliği hakkında ciddi sorular ortaya çıkmaktadır. Bu araştırma makalesinde, Edge Impulse yazılımı, Arduino Nano 33 BLE mikrodenetleyicisi ve LSM9DS1 ivme sensörü ile titreme tespiti için sistem yapılmıştır. Arka planda titreme ile istenmeyen genel bir sinyali ayırt edebilmektedir. Bu çalışmada, Edge Impulse makine öğrenme araçlarını kullanarak gelişmiş bir tahmine dayalı sistem tasarımıyla Nesnelerin İnterneti (IoT) ve makine öğreniminin birlikteliğinde ivme sensörü ile hareket tespiti yapılarak hastalığın erken tespitinin yapılması amaçlanmıştır. Edge Impulse, bu çalışmada titreme ve istenmeyen titreme için çeşitli örneklerden oluşan geniş bir veri kümesini eğitmek için kullanılmıştır. Önerilen sistemin %85 tanıma doğruluğu sağladığı bulunmuştur.

**Anahtar kelimeler:** Edge impulse, İvme ölçer, Anormallik tespiti, Parkinson hastalığı

#### 1 Giriş

Parkinson hastalığı, nöronların yıkımı, ölümünün neden olduğu ilerleyici nörolojik ve her geçen gün artan bir hastalıktır [1,2]. Dünya çapında, yaklaşık 10 milyon insanı etkileyen en yaygın nörodejeneratif hastalıklardan biri olarak da bilinmektedir. Merkezi sinir sisteminin kalıcı bir dejeneratif işlev bozukluğu olarak bilinir ve bunu hareket bozuklukları takip etmektedir. Bu bozukluklar, konuşma güçlüğü, titreme, kas sertliği, hareket yavaşlığı dengede bozulmalar gibi günlük hayatı zorlaştıran çeşitli semptomlara neden olmaktadır [3,4,5]. Bu semptomlar parkinson hastalarının yaşam standartlarını ciddi şekilde etkileyebilmekte ve klinik tanının temelini oluşturmaktadır [4]. Parkinson hastalığının en yaygın klinik belirtilerinden biri

#### Abstract

Parkinson's disease is a neurodegenerative disease in which tremor is the main symptom that threatens human health. Current research focuses on predicting, detecting or classifying Parkinson's Disease. In recent years, wearable motion detection systems have started to be created using various sensors. Reported results; While giving the impression that the problems are almost solved, serious questions arise about the representative capacity of the considered data and, accordingly, the reliability of the performance evaluation. In this research paper, the system for flicker detection is made with Edge Impulse and Arduino Nano 33 BLE LSM9DS1. It can distinguish between background flicker and an unwanted general signal. In this study, it is aimed to detect the disease early by using the Edge Impulse machine learning tools to detect motion with an acceleration sensor in combination with an advanced predictive system design, Internet of Things (IoT) and machine learning. Edge Impulse was used in this study to train a large dataset of various multiple samples for jitter and unwanted jitter. It was found that the proposed system provides 85% recognition accuracy.

**Keywords:** Edge impulse, Accelerometer, Abnormality detection, Parkinson's disease

titremedir ve hastaların yaşamlarında özellikle üst ekstremitelerde ciddi sıkıntılara neden olmaktadır [5]. Titreme, insan vücudunun farklı bölgelerini etkileyen istemsiz bir kas aktivitesidir. En yaygın olarak, ellerde titreme görülmektedir. Titreme yaşamı tehdit edici değildir fakat çoğu insanı rahatsız edici olabilmekte ve günlük sıradan görevleri yerine getirmeyi zorlaştırmaktadır [6]. Bu nedenle el titremesi tespiti; erken teşhis, erken tedavi ve erken remisyonun terapötik programı için önem arz etmektedir. Sağlık sektörü, insan hayatını etkilemede, bir kişinin yaşam tarzını değiştirmekte ve uzun ömürlülüğü sağlayan önemli derecede sorumlu yüksek öncelikli bir sektördür. IoT cihazlarının günümüzde en önemli özelliği "hastaları, sağlık profesyonellerini takip etmede ve hasta durumu izleme için uzaktan bakıcılara hayati hasta verileri tutmada önemli bir rol

\* Sorumlu yazar / Corresponding author, e-posta / e-mail: mine.boz7221@gop.edu.tr (M. Boz)

Geliş / Received: 18.07.2022 Kabul / Accepted: 08.11.2022 Yayınlanma / Published: 15.01.2023

doi: 10.28948/ngumuh.1144946

oynamaktadır". Makine Öğrenimi (ML), hastalara ve sağlık uzmanlarına verimli ve uygun maliyetli hizmetler sunmak için IoT teknikleriyle cihazların faydalarında devrim yaratan başka bir teknolojik alandır. Son yıllarda, sağlık hizmetleri için IoT ve ML ile ilgili birçok çalışma, çeşitli uluslararası araştırmacılar tarafından ilgi çekmektedir. Yöntemler hakkında, bu araştırmada, tele-tıbbi ve uzaktan sağlık hizmetlerine özel bir yoğunlaşma ile makine öğrenimi tabanlı IoT hizmetine yönelik bir girişimde bulunmaktadır.

Son zamanlarda bilgisayarla görme, dili doğal işleme gibi veri analizinde dahil olmak üzere çeşitli uygulama alanlarında makine öğreniminde oldukça başarılı olmuştur. Makine öğreniminin yüksek doğruluğu hem eğitim hem de çıkarım aşamaları için yüksek hesaplama ve bellek gerektirmektedir.

Bir makine öğrenme modelinin eğitimi, birden çok zaman diliminde tekrarlama olarak iyileştirilmesi gereken milyonlarca parametre sebebiyle alan ve hesaplama açısından oldukça maliyetli olmaktadır. Giriş verilerinin potansiyel olarak yüksek boyutluluğu ve giriş verileri üzerinden yapılması gereken milyonlarca hesaplama nedeniyle çıkarım, hesaplama açısından pahalıdır.

Makine öğrenimi, hesaplama ihtiyaçlarını karşılamak için bulut bilgi işleminden yararlanmaktadır. Bulut kaynaklarını kullanmak için; ağ kenarındaki verileri, veri kaynağı konumundan bulutta merkezi bir konuma taşınması gerekir. Verileri kaynaktan buluta taşınmanın bu potansiyel çözümü birçok zorluğu beraberinde getirmektedir.

1) Gecikme: Gerçek zamanlı çıkarımlar çoğu uygulama için kritik bir öneme sahiptir. Örneğin, otonom bir araçtan gelen kamera çerçevelerinin engelleri algılamak ve önlemek için hızlı bir şekilde işlemesi ve yanıt vermesi gerekmektedir. Ancak, çıkarım veya eğitim için buluta veri göndermek yayılma gecikmelerine neden olabilir. Gerçek zamanlı etkileşimli uygulamalar için gereken uçtan uca gecikmeli gereksinimleri karşılamamaktadır.

2) Ölçeklenebilirlik: Bağlı cihazların sayısı arttıkça buluta ağ erişiminde tıkanıklık olabileceğinden dolayı, kaynaklardan buluta veri göndermek ölçeklenebilirlik sorunlarının ortaya çıkmasına neden olmaktadır.

3) Gizlilik: Verilerin buluta gönderilmesi, verilere sahip olan veya davranışları verilerde yakalanan kullanıcılardan gelen gizliliği riske atmaktadır. Kullanıcılar, kişisel bilgilerini (ör. yüzler, konuşmalar) buluta yüklemekten ve uygulamanın bu verileri nasıl kullanacağı konusunda tedirgin olabilirler.

Edge bilişim, gecikme, ölçeklenebilirlik ve gizlilik zorluklarını gidermek için uygun bir çözüm sağlamaktadır. Gecikme zorluklarını uç bilgisayarların uç cihazlardaki veri kaynaklarına yakınlığı uçtan uca gecikmeyi azaltır ve böylece gerçek zamanlı hizmetlere imkan sağlamaktadır. Ölçeklenebilirlik sorununu ele almak için merkezi bir konumda ağ sıkışmalarından kaçınarak bilgi işlem kaynakları sağlayabilen ve işlemci sayısı ile ölçülebilen uç cihazlar, uç bilgi işlem düğümleri ve bulut veri merkezlerinden oluşan hiyerarşik bir sistem oluşturmaktadır. Verilerin kaynağa yakın bir yerde ya da yerel güvenilir bir uç sunucu tarafından analiz edilmesini sağlar, böylece genel internetin geçişini önler ve gizlilik, güvenlik saldırılarına karşı maruz kalmayı azaltmaktadır.

TinyML, mikrodenetleyiciler gibi minyatür ve düşük enerjili makinelerde çalışan modelleri araştıran ve öngören gömülü sistemler ve makine öğrenimi ile ilgili bir bilim alt dalıdır. Uç cihazlar söz konusu olduğunda çok küçük enerji ve küçük bant genişliğine dayalı düşük hareketlilik süresi modelinde yardımcı olmaktadır. TinyML tabanlı cihazların uça makine öğrenimi uygulamalarını çalıştırırken; günlerce, haftalarca, aylarca ve birkaç durumda, hatta uzun yıllar şarjız pillerle çalışmasına imkan sağlamaktadır [7].

Sağlık, akıllı şehir ve akıllı sistem için giyilebilir cihazlar gibi çeşitli versiyonlarda Nesnelere İnterneti (IoT) sensör verilerinin otomatik olarak anlaşılması istenmiştir. Giyilebilen sensörler üzerinde; insan hareketleri tanıma, akıllı bir şehirde yaya trafiği ve akıllı şebekede elektrik yükü tahmini sayılabilmektedir. IoT bağlamındaki bir fark, birlikte karşılaştırılması ve işlenmesi gereken birden çok veri akışı olabilmektedir. Ve bu veri akışları makine öğrenimi tarafından desteklenmesi gereken alan ve zaman korelasyonuna sahiptir. IoT derin öğrenme bağlamındaki bir başka çalışma alanı, derin öğrenme modellerini, yalnızca kilobayt belleğe ve düşük güçlü işlemcilerle sahip olan Arduino Nano 33 BLE gibi hesaplama açısından zayıf uç cihazlara uyacak şekilde sıkıştırılmaya olanak sağlamaktadır [8]. Gömülü makine öğrenimi ile Edge Impulse yazılım platformunu kullanarak çalışabilen ve algılama veya erken teşhis gerçekleştirebilen algoritmalar geliştirmek mümkün hale gelmiştir.

Bu çalışmada, Edge Impulse aracılığıyla parkinson hastalığının önceden tahmin edilmesi, hastaların hareketinin algılanması ve erken tanının sağlanmasına yardımcı olması amaçlanmıştır.


## 2 Materyal ve metot

Makine öğrenimi (ML), mevcut teknolojik alanın vazgeçilmez bir unsuru haline gelmiştir. Uç bilgi işlem ve Nesnelere İnterneti (IoT) ile birlikte, ağın ucundaki kaynak kısıtlı gömülü cihazlarda makine öğrenimi tekniklerini uygulamak için yeni bir fırsat sunmaktadır. Geleneksel makine öğreniminde, bir senaryoyu tahmin etmek için büyük miktarda bilgi işlem performansı gerekmektedir. Önde gelen bir gelişme platformu olan Edge Impulse; TinyML hedefli uç cihazlarda makine öğrenimi modelleri geliştiren bir bulut hizmetidir. Edge Impulse arayüzünü kullanarak geliştirilen yerleşik makine öğrenimi-TinyML paradigması, geleneksel yüksek kapasiteli bilgi işlem sistemlerden gömülü sistem cihazlarına yapmayı hedeflemektedir. Bu tür geçişler yapılırken, öğrenme modellerinin doğruluğunu korumak, verimli kaynaktan dağıtım kolaylığı sağlamak gibi çeşitli zorlukların üstesinden gelinmektedir. Bu, uç platformlar için AutoML işlemeyi destekler. Ayrıca bu tür cihazlarda öğrenme modellerini dağıtmak için akıllı telefonlar da dahil olmak üzere bir dizi kartı desteklemektedir. Eğitim bulut platformunda yapılır ve eğitilen model, veri iletili etkinleştirilmiş bir yol izlenerek bir uç cihaza aktarılabilir [9]. Bu çalışmada hastalardan gerçek veri toplamının uzun ve karmaşıklığını göz önünde bulundurularak Edge Impulse ile parkinson hastalığını erken teşhis için gerçek veri ile çok sayıda el titremesi verisi oluşturmak hedeflenmiştir.

İvme sensörü ve Arduino Nano 33 BLE devre kurularak; öncelikle farklı pozisyonlarla (“sabit duruş” ve “titreme”) cihazdan veriler alınmaktadır. Parkinson hastalarında el titremesini tespit etmek amacıyla sabit duruş ve titreme farklı pozisyonlarla 2 ayrı eğitim yapılmıştır.

## 2.1 Sistem içeriği

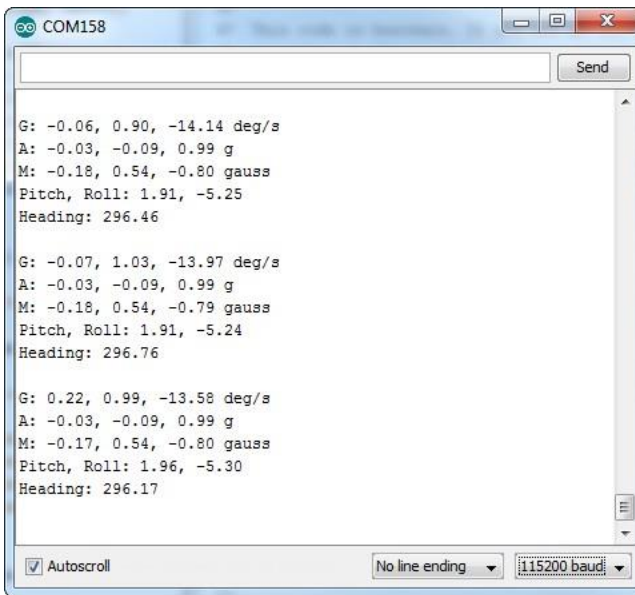
Bu çalışmanın ana bileşenleri Arduino Nano 33 BLE ve dahili LSM9DS1 modülüdür. Seri iletişim ile birbirine bağlıdır ve devre şeması Şekil.1’de gösterilmektedir.



Şekil 1. Devre şeması

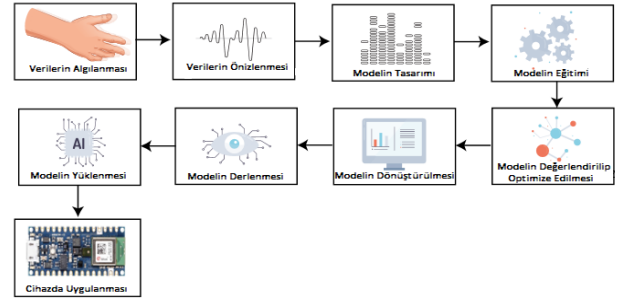
Arduino Nano 33 BLE, 64 MHz’de çalışan FPU’lu 32 bit Cortex M4 işlemcidir. Arduino tarafından oluşturulmuş geliştirme panosuna sahiptir. Bu sayede Arduino kütüphanesini kod yazarken kullanmayı kolaylaştırmaktadır. Arduino, bu üründe temel olarak Mbed kullanmaktadır, böylece hem Arduino kütüphanesini hem de Mbed kütüphanesini RTOS ile aynı anda kullanımı yapılmaktadır. Arduino, mikrodenetleyiciler üzerindeki genel gelişimin yanı sıra AI ile başlamak için en kolay hale getirenlerdir. Arduino, Edge Impulse AI modellerini geliştirme panolarına taşımayı kolaylaştırmıştır [10].

## 2.2 Çalışma basamakları



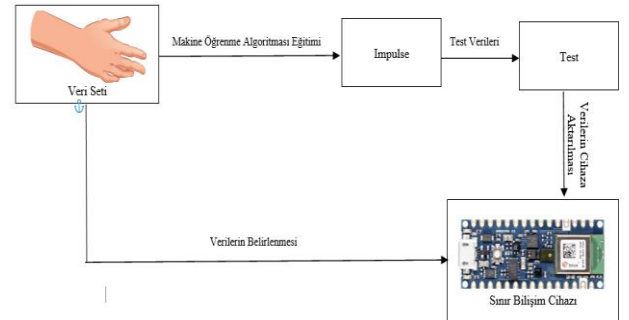
Şekil 2. Arduino seri ekran ölçümleri

LSM9DS1, 3 eksenli bir jiroskop ve 3 eksenli bir ivmeölçerden oluşmaktadır. İlk olarak, LSM9DS1 jiroskop açısı ve ivme bilgisini alır ve daha sonra orjinal verilere göre DMP işleme yoluyla dürtülü elde etmesi ve ardından üç eksenli Euler açısını, yani adım açısını, yuvarlanma açısını ve yalpalamayı elde etmek için tutum algoritmasını hesaplamaktadır. Daha sonra veriler seri port üzerinden ana bilgisayara iletmektedir [11]. Devrede kullanılan ivme sensörünün Arduino Nano 33 BLE Arduino Seri Ekran Ölçümleri Şekil.2’de gösterilmektedir. Makine öğrenimi modelini eğitmek ve test etmek için sensör verileri toplanmaktadır. Bu veriler, daha sonraki işlemler için Edge Impulse platformuna aktarılmıştır. Verileri Edge Impulse sunucusunda saklayabilmek için birkaç yol sağlanmıştır. Verileri iletimin yollarından biri olan ve iyi bir desteğe sahip olduğu Edge Impulse veri ileticisidir. Bu kenar darbe iletilici, Edge Impulse sunucularına doğrudan bağlantı yoluyla veri aktarımı sağlayan bir Edge Impulse yazılım paketi olan Edge Impulse Komut Satırı Arayüzü (CLI) araçlarında bulunan bir programdır. Bu program, verileri örneklemek için bir seri arabirim aracılığıyla bir mikro denetleyiciye bağlanmaktadır. Uygulama geliştirilmesinde izlenen metodoloji Şekil.3’de gösterildiği gibidir.



Şekil 3. TinyML'nin uygulama akışının blok şeması


Şekil.4 'de gösterilen makine öğrenimi çerçevesi, Edge Impulse modelini temsil eder. Arduino Nano 33 BLE ile Sınırlı Bilişim için Sinir Ağı modeli kullanarak, oluşturulan modelleri mikrodenetleyici üzerinde çalıştırılabilir. Bu çalışma için Edge Impulse üzerinde bulunan sınıflandırma algoritmalarından sinir ağları sınıflandırması (NN classification) kullanılmıştır.



Şekil 4. Edge impulse blok diyagramı

### 2.2.1 Yapay Sinir Ağı modeli (YSA) ;

Yapay sinir ağı (YSA), insan beynindeki nöronların yapısının çalışmasından esinlenerek modellenen bir donanım ve/veya yazılım sistemidir. YSA'lar ağırlıklarıyla birbirine bağlanmış elamanlardan oluşur. Kısaca sinir ağları olarak da adlandırılırlar. YSA için en sık kullanılan metotlardan, hataların geriye yayılma ilkesine göre çalışan geriye beslemeli (feedforward-back-propagation) modeli kullanılmıştır. Yapay sinir ağı hücresi; girdi tabakası, değişken ağırlık çarpanları, toplam fonksiyonu, tanımlama (aktivasyon) fonksiyonu ve çıktı tabakası olmak üzere beş ana bölümden oluşmaktadır. Şekil.5'te üç tabakalı yapay sinir ağı şeması gösterilmektedir.



Şekil 5. 3 Tabakalı yapay sinir ağı mimarisini

3 Tabakalı Yapay Sinir Ağı Mimarisinde,  $W_{ij}$  ve  $W_{jk}$  sırası ile girdi ve gizli tabakası, yine gizli tabaka ile çıktı tabaka arasındaki bağlantı ağırlıklarını ifade etmektedir. Bu değerler, bir önceki girdi verilerinin işlem yapılan eleman üzerindeki etkisini ifade eden katsayı değerleridir. İlk başta rastgele ağırlık değerleri alan bu katsayılar, eğitim aşamasında tahmin çıktıları ile gerçek çıktıları karşılaştırılarak sürekli değişmektedir. Ve hataları en aza indiren bağlantı ağırlık değerleri ayarlanıncaya kadar hata miktarları geriye doğru ilerlemektedir.

### 3 Bulgular ve tartışma

Toplanan veriler, önerilen bu makine Öğrenimi tekniğinde; veri toplama, veri ayrıştırma, makine öğrenimi modelleme ve kesinlik testi olarak bu adımlar izlenmelidir.

• Veri Toplama: Çeşitli kaynaklardan veri toplama ve analiz etme mekanizmasıdır. Süreçteki en zor ve en kritik adımlardan biri veri toplamadır. Çok fazla araştırma ve izleme gerektirmektedir.

• Veri Ayrıştırma: Bir veri dizisini başka bir veri biçimine dönüştürme işlemidir. Ayrıştırıcı dosyayı alarak insanlar tarafından kolayca anlaşılabilen bir dosya haline dönüştürmektedir.

• Makine Öğrenimi Modellemesi: Belirli bir işte en uygun olanı bulmak için makine öğrenimi modellerini eğitip değerlendirilen öz yinelemeli bir süreçtir.

• Doğruluk Testi: Sınıflandırma modelini doğru bir şekilde derecelendirmek için kullanılmaktadır. Model tarafından yapılan doğru tahminlerin yüzde olarak doğruluğu gösterilir.

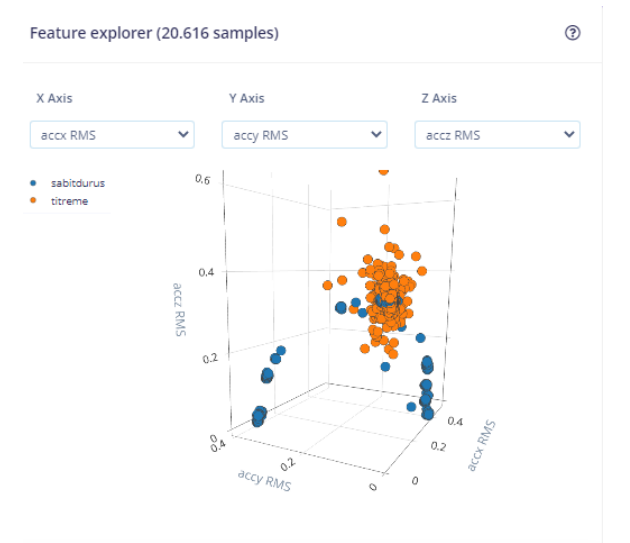


Şekil 6. Sabit duruş grafiği




Şekil 7. Titreme grafiği

Verileri elde ettikten sonra, Edge İmpulse da 'Spektral Analiz' sinyal işleme bloğunu kullanarak bir filtre uygulanmaktadır. Spektral analiz gerçekleştirilir ve frekans ve spektral güç verilerini çıkarmaktadır. Veri grafikleri Şekil.6 ve Şekil.7'de gösterildiği gibi iki ayrı kategoriye ayrılmaktadır.



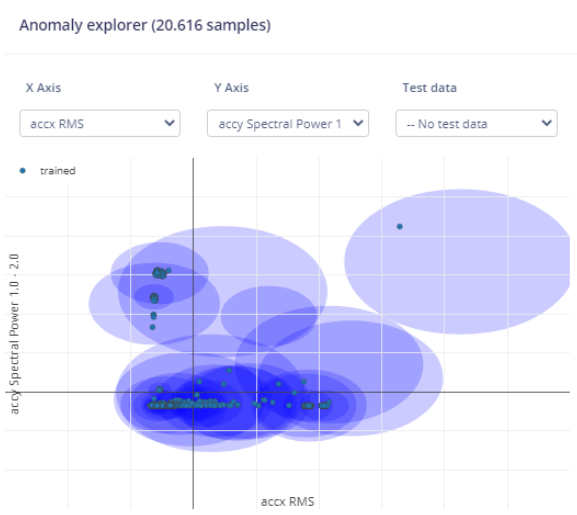
Şekil 8. Sinir ağı tarafından sınıflandırılan tüm eğitim veri kümesi



Şekil 9. Veri gezgini

20.616 verinin toplu bir grafikte yer aldığı parkinson tespitini yapabilmek adına tüm veri grafiklerinin karşılaştırılması 'Özellik Gezgini' komutu ile yapılabilmektedir. Sinir Ağı Tarafından Sınıflandırılan Tüm Eğitim Veri Kümesi Şekil.8'de gösterilmektedir. Verileri toplarken veri seti, eğitim ve test setlerine ayrılmaktadır. Model sadece eğitim seti ile eğitildi ve test seti, modelin görünmeyen veriler üzerinde ne kadar iyi performans göstereceğini doğrulamak için kullanılmıştır. Bu, modelin yaygın bir olay olan eğitim verilerine uyum oranını gösterecektir. Edge Impulse 'Model Test' sayesinde tüm test veri örneklerini sınıflandıracak ve modelin nasıl performans gösterdiğine dair genel bir doğruluk çıkartacaktır.

Veri kümesini keşfetmek, aykırı değerleri veya yanlış etiketlenmiş verileri bulmak için 'Veri Gezgini' özelliği kullanılmıştır. Veri gezgini modeli Şekil.9'da gösterilmektedir. Veri gezgini önce verilerden anlamlı özellikler çıkarır ve ardından bu özellikleri 2B alana eşlettirmektedir. Tüm veri kümesine genel bir bakış yapmamıza imkan sağlamaktadır.



Şekil 10. Anormallik tespit grafiği

Edge Impulse da kaydedilen verilerden anormallik tespit grafiği çıkartılarak parkinson hastalığının erken teşhisine yardımcı olmaktadır. Şekil.10'da gösterildiği gibi renk tonunun koyudan açığa doğru giden renk akışı titremenin yaygınlaştığını ve düz konumdan uzaklaştığını ifade etmektedir. Aynı zamanda anormallik değeri, bir anomalinin tespit edilip edilmediğini gösteren bir değerdir. Yani sinir ağı, eğitilmiş sınıflardan birinden çok uzakta olan bir değer algılamaktadır. Anormallik değeri, modelin zaten bildiği bir kümeye kadar olan ortalama değeri temsil edecektir. Bu değer sıfıra ne kadar yakın olursa o kadar iyi olduğunu göstermektedir.


Bu aşamalardan sonra 'Karışıklık Matrisi' oluşturularak Şekil.11'de gösterildiği gibi %85 doğruluk ve 0.38 kayıp tespit edilmiştir.

Eğitim Setindeki Veriler: 20.616

Eğitim Setindeki Sınıflar: 2 (Sabit Duruş, Titreme)

İşleme Süresi : 1 ms.

En Yüksek RAM Kullanımı : 1.7 K



Şekil 11. Tahmin doğruluğu ve kaybı ile sınıflandırılan veriler için karışıklık matrisi

Yukarda ifade edildiği gibi bu çalışma, el titremelerinin gömülü bir mikrodenetleyici ile hassas biçimde ölçülmektedir. Yine aynı mikrodenetleyici ile makine öğrenme yöntemleri ile sınıflandırma yapılarak çözüm üretmektedir. Bu yazıda elde edilen sonuçlarla, bir mikrodenetleyicinin sinir ağlarıyla birlikte kullanımının karmaşık laboratuvar değerlendirmelerine bir alternatif olabileceği ifade etmektedir. Parametrelendirme yerine sensör kullanımı ham verilerin doğrudan işlenmesinin daha etkili olduğunu ve klinik olarak ilgili bilgilerinin doğruluk oranını yükselteceğini göstermiştir. Pedrosa ve diğerleri tarafından yapılan araştırmada insan bedenine yerleştirilebilen bir mobil telefon kullanımı önerilmişti [12]. Fakat kullanılabilirliği ve uygulanabilirliği sorunlarından dolayı etkili olamamaktadır. Bu nedenle, bu çalışmada elde edilen sonuçlar, YSA tabanlı bir parametrik yaklaşımın yüksek doğrulukta bir sınıflandırma yeteneği sağlamasına rağmen, ham sinyal yönetimi ile kullanımının daha yüksek doğruluğu sağlanmasıyla tercih edilen teknik olarak kabul edilebileceğini göstermiştir.

Ancak, küçük örneklem boyutu nedeniyle sonuçlar titizlikle yorumlanmalıdır. Ayrıca, çalışmamızın sınırlı veri seti içerdiği göz önünde bulundurulmalıdır, önerilen yöntemlerin doğruluğu gerçek örneklerle test edilmemiştir. Gelecekte diğer öğrenme modelleri ve farklı sensörlerin kombinasyonu ile bunlar da daha iyi sonuçlar verileceği düşünülmektedir.

Levenberg-Marquardt algoritmaları Yapay Sinir Ağlarının ses veri seti için %95.89 ile en yüksek sınıflandırma doğruluğunu verdiği gözlemlenmiştir. Burada tartışıldığı gibi makine öğrenme tekniklerinin kullanılmasının erken teşhis ve tanı için büyük bir destek olacağına inanılmıştır. Parkinson hastalığı teşhisi için çok sayıda teknik mevcut olmasına rağmen, performansları hala kusurludur. Bu nedenle, CAD algoritmalarının doğruluğunu artırmak için daha fazla iyileştirmeye ihtiyaç vardır. Gelecekte, Parkinson tespiti ve sınıflandırması için genetik algoritma ve Extreme Learning Machine gibi diğer evrimsel algoritmaları kullanmaya başlanacaktır [13].

Konvolüsyonel sinir ağı modeli, EEG ve konuşma analizi gibi tek boyutlu sinyallerde de iyi performans göstermektedir. Bununla birlikte, derin öğrenme modelleri, hastalık tahmini ile ilgili kanıt eksikliğinden dolayı nörologlar ve diğer klinisyenler gibi son kullanıcılar tarafından henüz desteklenmemiştir. Bu yüzden derin öğrenme tabanlı CAD araçlarında daha sonra son kullanıcılar tarafından benimsenebilecek daha açıklanabilir ve yorumlanabilir yöntemleri benimsemeye ve parkinson hastalığından

etkilenen artan sayıda birey için sağlık bakım sonuçlarını iyileştirmeye teşvik edileceği düşünülmektedir [14].

Teknolojinin gelişmeye devam etmesi, parkinson hastalığı gibi pek çok hastalığında erken teşhisinin yapılabilmesinin önünün açılmasına yardımcı olmaktadır. Chatterjee, beyin BT görüntülerini sağlıklı bireyler ve parkinson hastaları arasındaki farklılıkları araştırmıştır [15]. Anese Picco, 18F-DOPA pozitron emisyon tomografisini parkinson hastalarında sağda ve sol putamenin son kısmında 18F-DOPA alımının azaldığını göstermektedir. İki kaudat çekirdeğin başında 18F-DOPA alımı asimetrik ve parkinson hastalığı olanlarda striatum kortekse oranının azaldığı görülmüştür [16]. Parkinson hastalığını analiz etmek için Thanawattano, tremor sinyallerindeki zamansal dalgalanmaları toplamıştır [17]. Parkinson hastalarında kas tonusunu ölçmek için Wright D., taşınabilir bir cihaz geliştirmiştir [18].

Fraivan ve ark. [19], günlük aktivitelere dayalı olarak parkinson hastalığı titreme olaylarını tespit etmek için bir akıllı telefonda ivmeölçeri kullanmıştır. Titremeleri %81 doğrulukla ayırt etmek için sınıflandırıcı olarak Yapay Sinir Ağlarını (YSA) kullanmışlardır.

Zhang ve ark. [20], parkinson hastalarının günlük aktivitelerindeki titremeleri tespit etmek için ivmeölçerler ve makine öğrenimi algoritmaları kullanmıştır. Altı hastalığı derecelendirme ölçeği aktivitesine ve dokuz günlük aktiviteye dayalı veri toplamışlardır. Sınıflandırma modellerinin doğruluğu %75 civarındadır. Ayrıca, verilerini bölümlere ayırmak için 30 saniyeden büyük boyutlara sahip birden çok pencere kullanmışlardır. Buna kıyasla çalışmamızda açık kaynaklı bir veri seti kullanarak, çeşitli parkinson hastalığını tespit etmek için nispeten iyi işleyen bir makine öğrenimi modelini eğitebilmesini sağladık. Nihai hedef, bunun gibi modelleri doğrudan yerleşik mikrodenetleyiciye veya Linux cihazına dağıtmak ve daha fazla tıbbi cihazın uça çıkarım yapmasına imkan sağlamaktır.

#### 4 Sonuçlar

Edge Impulse ML ardışık düzeninin eğitimini, testini ve doğrulamasının sonuçlarını göstermektedir. İlk olarak, modelin bir doğrulama seti üzerindeki eğitim sonuçları incelenmektedir. Bu sonuçlar yalnızca modelin eğitim verileriyle nasıl çalıştığını gösterdiği için, modelin test verileri aracılığıyla yeni verilere nasıl yanıt verdiğine de bakılmaktadır. Ayrıca, fiziksel bir cihazın modelinin çalışmasını gerçek zamanlı olarak doğrulamaktadır. Bu çalışmada gösterilen tüm resimler Edge Impulse kullanıcı arayüzü tarafından oluşturulmuştur. Edge Impulse aracılığıyla eğitimi ve testi, her ikisinin de uygulanabilir yöntemler olabileceğini göstermiştir. Her iki yöntemde de eğitim seti ve test setinde %85'lik yüksek doğruluk elde edilmektedir. Bu, Edge Impulse çerçevesi aracılığıyla cihazın kendisinde ML aracılığıyla insan etkinliği tanımlama gerçekleştirmek için herhangi bir rahatsız edici durumun söz konusu olmadığı ivmeölçer sensörlerinin de uygulanabilirliğini gösterilmektedir.

Birçok çalışma ile birlikte, normal koşullar altında parkinson hastalığı ön tanısı günümüzde esas olarak sağlık çalışanlarının tıbbi deneyimine dayanmaktadır. Ve klinik semptomlar için nesnel değerlendirme göstergelerinin

eksikliği makul bir tanı almayı zorlaştırmaktadır [21]. Edge Impulse, akademinin araştırma faaliyetlerini genel olarak uygulamalı dağıtılmış bilgi işleme yeniden odaklaması için benzersiz bir fırsat sunmaktadır. Edge Impulse makine öğrenme araçlarını kullanarak gelişmiş bir tahmine dayalı sistem tasarımıyla Nesnelerin İnterneti (IoT) entegrasyonu sayesinde ivme sensörü ile hareket tespiti yapılarak hastalığın erken tespiti yapılmasına imkan sağlamaktadır. Hareket sinyallerini yakalamak için kullanılan sensörler, sensörlerin konumları, örnekleme frekansı ve ölçüm aralığı belirtilerek grafikler oluşturulmuştur. Edge Impulse kullanarak bir uç cihazda gerçek zamanlı olarak bir makine öğrenimi modeli çalıştırılmıştır. Verileri yakalamak ve modeli dağıtmak için bir LSM9DS1 ivmeölçeri kullanılmıştır. Hareket sinyalleri, potansiyel uygulamaya uygun verimli konfigürasyonlara sahip ivmeölçer kullanılarak yakalanmıştır. Hareket sinyalleri, anormallik tespiti yapmak için ayrı ayrı gruplara sınıflandırılarak eğitimi tamamlanmıştır. Elde edilen hareket sinyalleri Edge Impulse üzerinden elde edilen grafiklerle yorumlanmaktadır.

#### Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

#### Benzerlik oranı (iThenticate): %5

#### Kaynaklar

- [1] S. Tadse, M. Jain, P. Chandankhede, Parkinson's detection using machine learning. Proceedings- 5th International Conference on Intelligent Computing and Control Systems ICICCS, 1081–1085, 2021. <https://doi.org/10.1109/ICICCS51141.2021.9432340>.
- [2] M. Saleh, M. Abbas, R. B. Le Jeannes, FallAID: An Open Dataset of Human Falls and Activities of Daily Living for Classical and Deep Learning Applications. IEEE Sensors Journal, 21(2), 1849–1858, 2021. <https://doi.org/10.1109/JSEN.2020.3018335>.
- [3] M. T. Ehsan, M. S. R. Sajal, K. A. Mamun, An automated cloud-based tool for Screening of Parkinson's disease in Bangladesh. International Conference on Robotics, Electrical and Signal Processing Techniques, 664–668, 2021. <https://doi.org/10.1109/ICREST51555.2021.9331233>.
- [4] K. Rezaee, S. Savarkar, X. Yu, J. Zhang, A hybrid deep transfer learning-based approach for Parkinson's disease classification in surface electromyography signals. Biomedical Signal Processing and Control, 71, 103161, 2022. <https://doi.org/10.1016/J.BSPC.2021.103161>.
- [5] L. Tao, X. Wang, X. Peng, P. Yang, J. Qi, Y. Yang, Activity Selection to Distinguish Healthy People from Parkinson's Disease Patients Using I-DA. Proceedings - 2021 17th International Conference on Mobility, Sensing and Networking, MSN, 66–73, 2021. <https://doi.org/10.1109/MSN53354.2021.00025>.
- [6] L. Tong, J. He, L. Peng, CNN-Based PD Hand Tremor Detection Using Inertial Sensors. IEEE Sensors Letters, 5(7), 2021. <https://doi.org/10.1109/LSSENS.2021.3074958>.

- [7] A. Rana, Y. Dhiman, R. Anand, Cough Detection System using TinyML. Proceedings- International Conference on Computing, Communication and Power Technology, IC3P, 119–122, 2022. <https://doi.org/10.1109/IC3P52835.2022.00032>.
- [8] J. Chen, X. Ran, Deep Learning With Edge Computing: A Review. Proceedings of the IEEE, 2019. <https://doi.org/10.1109/JPROC.2019.2921977>.
- [9] P. P. Ray, A review on TinyML: State-of-the-art and prospects. Journal of King Saud University - Computer and Information Sciences, 34(4), 1595–1623, 2022. <https://doi.org/10.1016/J.JKSUCI.2021.11.019>.
- [10] B. Wiggård and T. Eng, Power Consumption when using AIModels on microcontrollers. <http://urn.kb.se/resolve?urn=urn:nbn:se:liu:diva-186026>, 2022. <https://doi.org/10.1515/CDBME-2020-3097/MACHINEREADEABLECITATION/RIS>.
- [11] X. Pengfei, C. Shiwen, Y. Zhang, Design of Pose measurement and Display system based on STM32 and MPU6050. Proceedings - International Conference on Intelligent Computing, Automation and Systems, ICICAS, 71–74, 2021. <https://doi.org/10.1109/ICICAS53977.2021.00021>.
- [12] S. A. Hossein Tabatabaei, D. Pedrosa, C. Eggers, M. Wullstein, U. Kleinholdermann, P. Fischer, K. Sohrabi, Machine Learning Techniques for Parkinson's Disease Detection using Wearables during a Timed-up-and-Go-Test. Current Directions in Biomedical Engineering, 6(3), 376–379, 2020.
- [13] G. Pahuja, T. N. Nagabhushan, A Comparative Study of Existing Machine Learning Approaches for Parkinson's Disease Detection. 67(1), 4–14, 2018. <https://doi.org/10.1080/03772063.2018.1531730>.
- [14] H. W. Loh, W. Hong, C. P. Ooi, S. Chakraborty, P. D. Barua, R. C. Deo, J. Soar, E. E. Palmer, U. R. Acharya, Application of Deep Learning Models for Automated Identification of Parkinson's Disease: A Review (2011–2021), 2021. <https://doi.org/10.3390/S21217034>.
- [15] J. Chatterjee, A. Saxena, G. Vyas, A. Mehra, A computer vision approach to diagnose Parkinson Disease using Brain CT Images. In 2018 Second International Conference on Computing Methodologies and Communication (ICCMC) (pp. 463–467), IEEE, 2018. <https://doi.org/10.1109/ICCMC.2018.8488034>.
- [16] A. Picco, S. Morbelli, A. Piccardo, D. Arnaldi, N. Girtler, A. Brugnolo, I. Bossert, L. Marinelli, A. Castaldi, F. de Carli, C. Campus, G. Abbruzzese, F. Nobili, Brain 18F-DOPA PET and cognition in de novo Parkinson's disease. European Journal of Nuclear Medicine and Molecular Imaging, 42(7), 1062–1070, 2015. <https://doi.org/10.1007/S00259-015-3039-0/FIGURES/3>.
- [17] C. Thanawattano, C. Anan, R. Pongthorseri, S. Dumnin, R. Bhidayasiri, Temporal fluctuation analysis of tremor signal in Parkinson's disease and Essential tremor subjects. Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 6054–6057, Milan, Italy, 25–29 August 2015. <https://doi.org/10.1109/EMBC.2015.7319772>.
- [18] D. Wright, K. Nakamura, T. Maeda, K. Kutsuzawa, K. Miyawaki, K. Nagata, Research and development of a portable device to quantify muscle tone in patients with parkinsons disease. Proceedings of the 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS'08-“Personalized Healthcare through Technology,” 2825–2827, Vancouver, BC, Canada, 20–25 August 2008. <https://doi.org/10.1109/IEMBS.2008.4649790>.
- [19] L. Fraiwan, R. Khnouf, A. R. Mashagbeh, Parkinson's disease hand tremor detection system for mobile application. Journal of Medical Engineering & Technology, 40(3), 127–134, 2016. <https://doi.org/10.3109/03091902.2016.1148792>.
- [20] A. Zhang, A. Cebulla, S. Panev, J. Hodgins, & F. de La Torre, Weakly-supervised learning for Parkinson's Disease tremor detection. Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 143–147, Jeju, Korea (South), 11–15 July 2017. <https://doi.org/10.1109/EMBC.2017.8036782>.
- [21] J. Meng, Q. Niu, X. Huo, H. Zhao, L. Zhang, X. Wang, Y. Wang, A Detection Method for Parkinson's Hand Tremor Based on Machine Learning. China Automation Congress, CAC, 4105–4109, Beijing, China, 22–24 October 2021. <https://doi.org/10.1109/CAC53003.2021.9728408>.

