



Balistokardiyografi sinyalleri ile derin öğrenme tabanlı hipertansiyon tespiti

Deep learning based hypertension detection with ballistocardiography signals

Salih Taha Alperen Özçelik^{1,*}, Hakan Uyanık², Abdulkadir Şengür³

¹ Bingöl Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 12000, Bingöl Türkiye

² Tunceli Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 62000, Tunceli Türkiye

³ Fırat Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 23000, Tunceli Türkiye

Öz

Kan basıncı, damarlardaki kanın damar duvarlarına uyguladığı basınçtır. Bu basınç değerinin normal kabul edilen seviyelerin üzerinde seyir etmesi yüksek tansiyon (YT) veya hipertansiyon (HPT) olarak bilinir. Hayat kalitesini negatif yönde etkileyen, çoğu zaman organlarda çeşitli tahribatlara sebep olan ve ölümlere yol açabilen bu sağlık probleminin teşhisi oldukça önemlidir. Bu çalışmada, balistokardiyografi (BKG) sinyalleri kullanılarak HPT'nin otomatik teşhisine yönelik bir yöntem önerilmiştir. Bunun için BKG sinyalleri, sürekli dalgacık dönüşümü filtre bankası (SDDFB) yöntemi kullanılarak zaman-frekans domenine taşınmıştır. Bu işlemler yapılırken kullanılan dönüşüm yönteminde bazı parametre ayarları gerçekleştirilerek dönüşümün kalitesi artırılmıştır. Daha sonra elde edilen görüntüler ResNet18, ResNet50, VGG16 ve AlexNet evrişimsel sinir ağlarıyla sınıflandırılmış ve elde edilen sonuçlar karşılaştırılmıştır. Önerilen yöntem ile ResNet18, ResNet50, VGG16 ve AlexNet mimarileri için sırasıyla %98,92, %99,34 ve %99,22 ve %98,07 sınıflandırma doğruluğu elde etmiştir. Elde edilen bu yüksek sınıflandırma sonuçları önerilen yöntemin hipertansiyon teşhisi için kullanılabileceğini ispatlar niteliktedir.

Anahtar kelimeler: Hipertansiyon, BKG sinyali, Derin öğrenme, Sürekli dalgacık dönüşümü filtre bankası

1 Giriş

Hipertansiyon, kan basıncının kalp hastalığı gibi sağlık sorunlarına yol açacak kadar yüksek olması durumuna verilen isimdir [1]. Kalpten geçen kanın vücutta dolaşımını sağlamak için kullanılan bir ölçüm olan kan basıncının normal olarak 120/80 mmHg olması gerekmektedir. 140/90 mmHg üzeri bir değerde olursa hipertansiyon tanısı koyulabilir. Özellikle son on yılda hipertansiyonun dünya çapında yaygınlaştığı görülmektedir [2]. Dünya Sağlık Örgütü verilerine göre hipertansiyon 1990'dan 2021'e kadar ikiye katlanmıştır [3]. Hipertansiyon kontrol altına alınmazsa artan basıncın kalp kasına zarar vermesiyle kalp hastalıklarına yol açabilir. Bunun dışında böbrek hastalıkları, felç gibi ciddi sağlık sorunlarına yol açabilir [4]. Kendini göstermeden gizli bir şekilde ilerleyen bir hastalık olduğundan erkenden tanı koyulabilmesi oldukça önemlidir.

Abstract

Blood pressure is the pressure exerted by the blood in the vessels against the vessel walls. If this pressure value is above normal levels, it is known as high blood pressure (HBP) or hypertension (HPT). The diagnosis of this health problem, which negatively affects the quality of life, often causes various damage to organs and can lead to death, is very important. In this study, a method for automatic diagnosis of HPT using ballistocardiography (BCG) signals is proposed. For this, BCG signals are transferred to the time-frequency domain using the continuous wavelet transform filter bank (CWTFB) method. The quality of the conversion has been increased by making some parameter settings in the conversion method used while performing these operations. Then, the obtained images were classified with ResNet18, ResNet50, VGG16 and AlexNet convolutional neural networks and the obtained results were compared. With the proposed method, classification accuracy of 98.92%, 99.34%, 99.22% and 98.07% was obtained for ResNet18, ResNet50, VGG16 and AlexNet architectures, respectively. These high classification results obtained prove that the proposed method can be used for the diagnosis of hypertension.

Keywords: Hypertension, BCG signals, Deep learning, Continuous wavelet transform filter bank

Bu sebeple kalp hızı değişkenliğinin analizinin yapılması ve kardiyak anomalilerin araştırılmasını kolaylaştırmak için hipertansiyon ölçüm yöntemleri geliştirilmiştir. Elektrokardiyografi (EKG), sismokardiyografi (SKG), forcekardiyografi (FKG), girokardiyografi (GKP) ve balistokardiyografi (BKG) gibi fizyolojik sinyaller hipertansiyonun teşhisi için kullanılan bazı biyolojik sinyallerdir. EKG bunlardan en popüler olanıdır. EKG elektriksel aktiviteyi ölçerken BKG kalp hareketine dayalı mekanik titreşimleri kaydeder [5]. Bu sinyalden BKG, sensörlü yatak üzerinden hastanın vücuduna elektrot yerleştirmeye ihtiyaç duymadan uyku esnasında kayıt edilebildiği için EKG'ye kıyasla daha uygundur [6]. Bu durum hastanın uyku boyunca kalp atış düzensizliklerinin tespit edilip hastalıklarına teşhis koyulabilmesine olanak sağlar. Uyku esnasında atriyal fibrilasyon ve sinüs ritmi

ataklarının analizi için BKG sinyallerinin kullanılabilmesi EKG'ye karşı bir diğer avantajdır [7].

Parmar vd. [8] çalışmalarında kullandıkları EKG sinyallerini Fourier dönüşümü yardımıyla 8 adet içsel alt bant fonksiyonuna ayırdı. Bunun için Fourier ayrıştırma yöntemi ve tek tip kosinüs modülasyonu filtre bankasını kullanan araştırmacılar, Log enerji özelliklerini çıkardı. Çalışmalarında SHAREE [9] ve MIT-BIH [10] veri setlerini kullanan araştırmacılar en k en yakın komşu (KEYK) algoritmasını kullanarak 10 katlı çapraz doğrulama ile sınıflandırma gerçekleştirerek Fourier ayrıştırma yöntemi için %99.91, kosinüs modülasyonu filtre bankası için %99.99 başarı elde etti.

Soh vd. [11], yine MIT-BIH ve SHAARE veri setlerini kullandıkları çalışmalarında hipertansiyonu otomatik olarak teşhis eden bir model önerdi. Araştırmacılar EKG sinyallerini ayırık dalgacık dönüşümü (ADD) kullanarak parçalara ayırıp alçak ve yüksek geçiren filtreler kullanarak sinyalleri gürültülerden arındırdı. Evrişimsel sinir ağına 10 katlı çapraz doğrulama ile sınıflandırma gerçekleştiren araştırmacılar %99.99 sınıflandırma başarısı elde etti.

Yine SHAREE veri setini kullanan Rajput vd. [12] EKG sinyallerinden sinyal fraktal boyutundan log entropi özelliklerini çıkararak yeni bir hipertansiyon tanı endeksi geliştirdi. Geliştirdikleri yöntem SHAREE veri setinden derin öğrenme tabanlı bir sınıflandırma ile %99.68 başarı oranına ulaştı.

EKG sinyalinde olduğu gibi EEG ve EMG gibi fizyolojik sinyallerin işlenmesinde kullanılan dalgacık dönüşümü yöntemleri yüksek sınıflandırma başarılarının elde edilmesinde açısından oldukça efektif olmuştur [13-17].

Song vd. [18], 8 kadın 10 erkeğin katılımıyla kendileri tarafından oluşturulan veri setinde uyku esnasında mikro harekete duyarlı şilte (MHDŞ) ile sürekli BKG sinyallerini kaydetti. Topluluk mod ayrıştırma (TMA) dayalı bir yöntem kullanan araştırmacılar BKG sinyallerinin doğrusal olmayan analizi, zaman alanı analizi ve frekans alanı analizinden kalp atış hızı değişkenliği (KAHD) ve kalp atışı aralıkları (KAA) özelliklerini çıkararak Naive Bayes sınıflandırıcı kullanarak %92.3 sınıflandırma başarısı elde etti.

Bu çalışmada kullanılan veri setini oluşturan Liu vd. [19], 61 hipertansiyon ve 67 normal tansiyonlu deneyin katılımıyla gerçekleştirdikleri bir çalışmada gece uykusu boyunca BKG sinyallerini sürekli bir şekilde kaydetti. Araştırmacılar ilk adımda BKG sinyallerinden örnek entropi, yaklaşık entropi, KAA, zaman ve frekans alanı ve BKG dalgalanma özelliklerini çıkardı. Sınıflandırma ve birliktelik kuralı madenciliğini birleştirerek hipertansiyonu tanımlamak için yeni bir yöntem geliştirdi. Uyguladıkları yöntem doğruluk için %84.4, kesinlik değeri için %82.5 ve geri çağırma oranı için %85.3 başarı oranı elde etmiştir. Bu veri setini kullanan diğer araştırmacılardan olan Rajput vd. [20], sürekli dalgacık dönüşümü (SDD) kullanarak BKG sinyallerini skalogram görüntülerine çevirdi. İki boyutlu evrişimsel sinir ağı (ESA) modeliyle sınıflandırma gerçekleştiren araştırmacılar %86.14'lük bir sınıflandırma başarısı elde etti. [19]'te oluşturulan veri setini kullanan bir diğer araştırmacı grubu Gupta vd. [21], çoklu evren optimizasyonu (ÇEO) algoritmasıyla birleştirilmiş

ayarlanabilir Q faktörü dalgacık dönüşümünü kullandı. BKG sinyallerini alt bantlara ayıran araştırmacılar her bant için Shannon entropisi, log enerjisi, Hjorth karmaşıklığı, standart türev, çarpıklık, ortalama kare değeri, basıklık, çarpıklık, ortalama değer, maksimum değer ve minimum değer olmak üzere toplamda 11 istatistiksel özellik çıkardı. Kruskal-Wallis yöntemiyle özellik azaltan araştırmacılar en önemli 7 özelliği KEYK sınıflandırıcısına vererek %92.21'lik bir sınıflandırma başarısı elde etti. Gupta vd. [22] yaptıkları başka bir çalışmada, [19]'te üretilen veri setini kullanarak BKG sinyallerini görüntüleri zaman-frekans (Z-F) spektral görüntülere dönüştürerek hipertansiyonu otomatik olarak tanıyacak bir sistem geliştirdi. Z-F görüntülerini elde etmek için Gabor dönüşümünü (GD), düzleştirilmiş Pseudo-Wigner Ville dağılımı (DPWVD) ve kısa zamanlı Fourier dönüşümü (KZFD) kullandılar. Hyp-Net adını verdikleri ESA mimarisinde 10 kat çapraz doğrulama (KÇD) ile %97.65'lik bir sınıflandırma başarısı elde ettiler. Seok vd. [23], BKG sinyallerini ölçen bir sandalye aracılığıyla 30 katılımcıdan oluşan bir veri seti oluşturdu. İki bölümden oluşan deneyin ilk bölümünde iki kanallı BKG sinyallerini ve tansiyon değerlerini kaydettiler. İkinci bölümde denek koşu bandında koştuktan sonra aynı ölçümleri tekrar yaptılar. Giriş sinyallerindeki gürültüyü ortadan kaldırmak ve model eğitimi için anlamlı bir aşama oluşturmak için EMD yöntemiyle Hilbert dönüşümünü kullandılar. Yazarlar, iki kanallı BKG fazından sistolik ve diyastolik kan basınçlarını (SKB ve DKB) tahmin eden bir ESA regresyon modelini çalıştırdıktan sonra ilk seansın (dinlenme) ve ikinci seansın (iyileşme) sonuçlarını karşılaştırdı. Yine başka bir çalışmada Rajput vd. [24], normotansif ve hipertansif denekleri tespit edebilmek için BKG sinyallerini kullandı. Araştırmacılar [19]'te oluşturulan veri setini kullanarak BKG sinyallerini ampirik mod ayrıştırma (AMA) ve dalgacık dönüşümü (DD) kullanarak 30 saniyelik bölümlere ayırdı. DD ve AMA kullanılarak, BKG sinyali beş alt banda ve beş içsel mod fonksiyonlarına (IMF'ler) bölündü. Alınan özellikleri sınıflandırmak için toplu yumuşak sınıflandırıcı (TYS) sınıflandırıcısını kullandılar. Araştırmacılar, DD için 10 kat çapraz doğrulama kullanarak %89'lük bir sınıflandırma doğruluğu elde etti. Yine kendi yaptığımız bir önceki çalışmada Özçelik vd. [25], [19]'te oluşturulan veri setindeki BKG sinyallerini 30 saniyelik parçalara bölerek spektrogram görüntülerine dönüştürdük. Sınıflandırmak için Convmixer mimarisini kullandık. Convmixer ile %97.69'lük bir sınıflandırma doğruluğu elde ettik.

Bu çalışmada, BKG sinyallerinden hipertansiyonu otomatik olarak teşhis etmek için SDDFB yöntemine dayanan bir evrişimsel sinir ağı (ESA) modeli geliştirildi. Başlangıçta giriş BKG sinyallerini medyan mutlak sapma (MMS) yaklaşımını kullanarak normalleştirildi. Ardından, giriş BKG sinyallerini birden çok BKG sinyaline bölmek için çakışmayan bir sinyal bölme yöntemi uygulandı. Her parçanın uzunluğu 30 saniye seçildi. Her bir sinyal parçası daha sonra SDDFB yaklaşımı kullanılarak zaman frekans domeninde görselleştirilerek görüntü haline dönüştürüldü. BKG ısı haritası görüntüleri elde edildikten sonra özellik çıkarma ve sınıflandırma işlemleri AlexNet, ResNet50, Vgg16, ResNet18 mimarileri üzerinden gerçekleştirildi.

Çalışmada kullanılan BKG veri setinde 128 kişi bulunmaktadır. 128 kişiden 61'i hipertansiyon, geri kalan 67 kişi normal tansiyon olarak etiketlenmiştir. Deneysel çalışmalar sırasında, önerilen yöntemin performansını değerlendirmek için çeşitli istatistiksel değerlendirme ölçütleri kullanıldı. Elde edilen sonuçlar mevcut yaklaşımlarla da karşılaştırılmıştır. Bu çalışmanın başlıca katkıları;

- [19]'te oluşturulan veri seti için en yüksek başarımlar elde edildi.
- Mimariler kıyaslanarak hız ve performans açısından karşılaştırıldı.

2 Veri seti

Bu çalışmada Liu vd. [19] tarafından oluşturulan veri seti kullanılmıştır. Araştırmacılar bu veri setini oluştururken RS-611 adını verdikleri bir sinyal toplama sistemi kullanmışlardır. Kullandıkları sinyal toplama sisteminde kalp hareketlerinin neden olduğu BKG sinyalleri 100 Hz örnekleme frekansıyla 16 bitlik analog-dijital dönüştürücü yardımıyla kaydedilmiştir. Veri seti, kriterleri karşılayan hipertansiyonu olan 61 kişi ve normal tansiyona sahip 67 kişi ile oluşturulmuştur. Veri setinin istatistiksel bilgileri Tablo 1'de verildiği gibidir.

Tablo 1. Kullanılan veri setinin istatistiksel özellikleri

Kişi Bilgileri	Hipertansiyon	Normal Tansiyon
Kişi Sayısı	61	67
Cinsiyet (E/K)	33/38	35/32
Yaş	55.6 ± 7.9	53.2 ± 9.2
Kalp Atışı (BPM)	77.1 ± 9.2	73.6 ± 8.3
Vücut Kitle İndeksi (kg/m ²)	24.3 ± 3.6	23.7 ± 3.4
Sistolik Kan Basıncı (mmHg)	155.6 ± 11.2	112.1 ± 15.7
Dialostik Kan Basıncı (mmHg)	103.6 ± 8.2	74.4 ± 6.3

3 Metodoloji

Bu çalışmada uygulanan yöntemin akış şeması Şekil 1'de gösterilmektedir. Sınıflandırılacak BKG sinyalleri görüntülere dönüştürülmeden önce bir takım ön işlemlerden geçirilir. Bu amaçla, ilk adımda ham BKG sinyallerinin genliğinin ortalandığı ve z-skoru normalizasyonu ile 0 medyan ve medyan mutlak sapmanın 1 olacağı şekilde ölçeklendiği bir normalleştirme prosedürü uygulanır. Ham BKG sinyallerinin normalizasyonu zorunludur, çünkü bu sinyaller toplanırken deneklerin vücut ağırlıkları doğrudan BKG sinyallerini etkiler [26]. Ön işlemden geçirilen BKG sinyalleri daha sonra, sinyal işleme alanında sıklıkla uygulanan bir yöntem olan örtüşmesiz segmentasyon işleminden geçirilerek parçalara ayrılır. Bir sonraki adımda, parçalara ayrılan sinyaller tasarlanan bir bant geçiren filtre ile filtrelenerek görüntüye dönüştürülmek üzere sonraki adıma aktarılır. Bu süreçte bazı parametre tercihleri (dalgacık tipi, ölçek, sınırlayıcı tipi ve zaman bant genişliği) ile en uygun görüntünün elde edilmesi amaçlanmaktadır. Çünkü daha önceki çalışmalarda [27-34] gösterildiği gibi, 1s

haritası görüntü elde etme yöntemlerinde zaman-frekans çözünürlüğü dengesi sonuçlar üzerinde oldukça etkili olmaktadır. Uyku halindeki deneklerden elde edilen BKG sinyalleri, 30 saniyelik parçalara bölünmüş ve toplamda hipertansiyon sınıfından 3000 sinyal parçası normal tansiyondan 3000 sinyal parçası olmak üzere toplamda 6000 sinyal parçası rastgele olarak seçilmiş ve bu sinyal parçaları SDDFB yöntemiyle ırs haritası görüntülerine dönüştürülmüştür. Elde edilen görüntüler ResNet18, ResNet50, VGG16 ve AlexNet evrimsel sinir ağları yardımıyla sınıflandırılır.

3.1 Normalizasyon

Normalizasyon işlemi yukarıda belirtildiği üzere deneklerin vücut ağırlıklarındaki farklılıkların BKG sinyallerine olan yansımalarının elimine edilmesi için uygulanmaktadır. Bunun için medyan mutlak sapma (MMS) kullanılarak z-skoru normalizasyon tekniği kullanılmıştır. MMS yöntemi, normalleştirilecek verilerde değer dağılımında yüksek farklılıklar olduğunda tercih edilen bir yöntemdir. Verilerdeki değerlerin dağılımındaki farklılıkların fazla olması standart sapma hesabında bozucu bir etkiye sahiptir. Medyan mutlak sapma içinse bu durum böyle değildir. Bir veri kümesinin medyan mutlak sapması aşağıdaki eşitlik yardımıyla hesaplanır[35].

$$MMS = \text{median}(|x - \bar{X}|) \quad (1)$$

3.1 Sürekli dalgacık dönüşümü filtre bankası

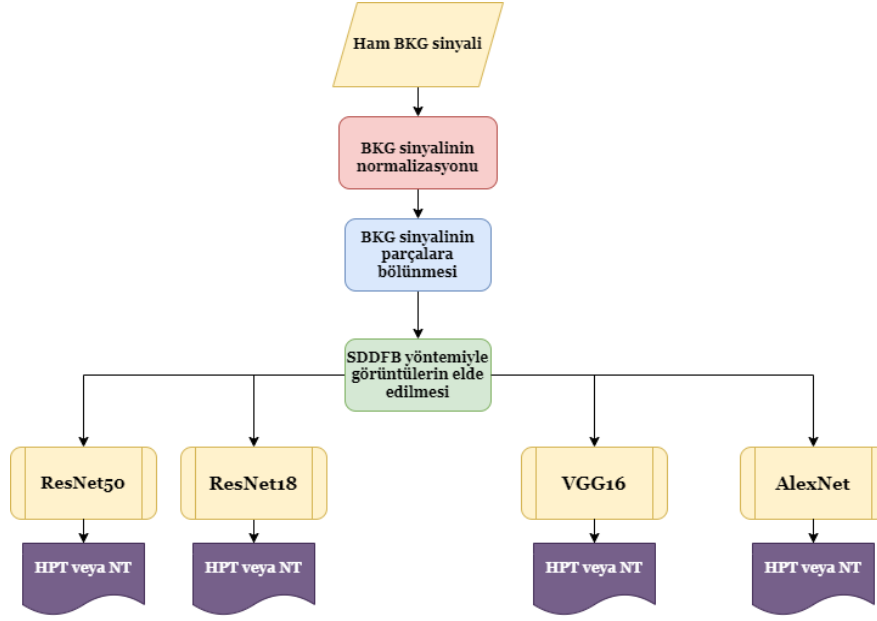
Filtre bankasında dalgacık tipi olarak analitik Morse dalgacık tipi seçilmiştir. Analitik dalgacık olarak isimlendirilen karmaşık değerli dalgacıklar, sadece pozitif gerçek eksenini destekleyen Fourier dönüşümlerine sahiptir. Zaman içinde genlik ve frekans değişimleri olan ayarlanmış sinyallerin incelenmesi için faydalıdır. Morse dalgacıkları da analitik dalgacık ailesinin bir üyesidir. Genelleştirilmiş Morse dalgasının Fourier dönüşümü (2) nolu eşitlikte verilmiştir [36].

$$\Psi_{\beta,\gamma}(\omega) = U(\omega) a_{P,\gamma} \omega^{\frac{P^2}{\gamma}} e^{-\omega\gamma} \quad (2)$$


U(ω): Birim adımı, a_(P,γ): Normalleştirme sabiti, P²: Zaman-bant genişliği, γ: Morse dalgacığının simetrisini karakterize eden parametre

Bu çalışmada simetri parametresi gamma (γ) 3 seçilmiştir. Bu simetri parametresi değeri için zaman bant genişliği parametresini azaltmak dalgacığın simetrikliğini azaltacağından zaman bant genişliği varsayılan değer olan 30' dan 60' a yükseltilmiştir. Bu sayede dalgacık zamanda daha yavaş salınarak hem simetri hem de zaman bant genişliği arttıkça daha dar bir frekansa sahip olarak daha iyi ırs haritası görüntüleri oluşturacaktır. Şekilde bu parametrenin ayarlanmasının zaman ve frekansı nasıl etkilendiği görülmektedir.


Sürekli dalgacık dönüşümü filtre bankasında oktav başına ses katsayısı sinyalin hangi ölçeklere ayrılacağını belirten parametredir. Oktav başına ses katsayısı bu çalışma için 10 olarak seçilmiştir.



Şekil 1. Geliştirilen yönteme ilişkin işlem adımları

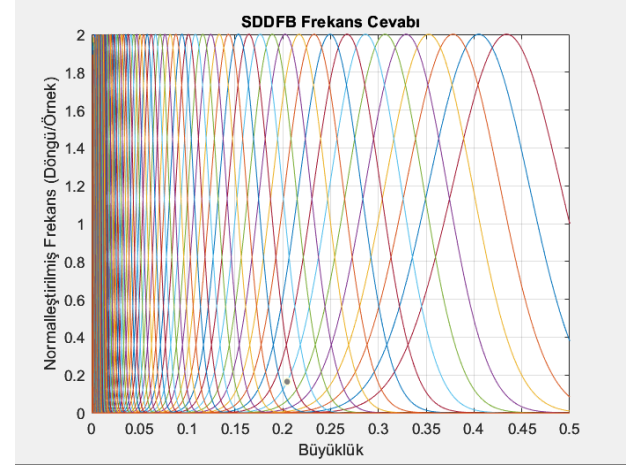


Şekil 2. Ham BKG sinyalinin bir parçasının normalizasyon sonraki durumu



Şekil 3. Zaman-Bant genişliği parametresinin artırılmasının salınımına etkisi

Verilerin sınırda nasıl ele alınacağını belirleyen parametre olan sinyal sınır uzantısı “Yansıma” seçilmiştir. Bu parametrelere göre SDDFB frekans cevabı Şekil 4’teki gibi olacaktır.




Şekil 4. SDDFB frekans cevabı.

Görüntülerin elde edilmesi ise şu şekilde gerçekleşir. SDDFB yardımıyla BKG sinyali her satırın bir ölçüğe karşılık geldiği 2 boyutlu matrise dönüştürülür. Bu matriste negatif değerler de bulunabileceği için mutlak değeri alınır. Daha sonra logaritması alınıp kendi belirlediğimiz 10 katsayısı ile çarpılarak normalleştirilir. Her 30 saniyelik segmentten bir görüntü elde edilecek şekilde algoritma çalıştırılır. Elde ettiğimiz ısı haritası görüntüsünden sırasıyla NT ve HT bireylerden birer örnek Şekil 5’te verilmiştir.

3.2 ResNet18

7x7’lik bir evrişim ResNet18’in 18 katmanının ilk katmanıdır. Birbiriyle aynı 4 evrişim katmanından oluşur. Her katman 2 artık bloktan oluşur [37-38].



Şekil 5. Veri setindeki bir deneğin BKG sinyalinden oluşturulan SDDFB ısı haritası görüntüleri (a) normal tansiyon (b) hipertansiyon

Her bloğun 2 ağırlık katmanı ve bir ReLu tarafından ikinci ağırlık katmanının çıktısıyla birleşen bir atlama bağlantısı vardır. Çıktı evrişim katmanının girdisiyle eşleşiyorsa aynılık bağlantısı kullanılır. Bununla birlikte giriş ve çıkış karşılaştırılabilir değilse atlama bağlantısında bir havuzlama gerçekleştirilir. ResNet18 mimarisinin giriş boyu 224x224x3 olduğundan ResNet18'e verilecek SDDFB ısı görüntüleri bu boyuta ayarlanmıştır.

3.3 ResNet50

ResNet50, 50 katmanlı bir derin öğrenme ağ mimarisi olup 3 katmandan oluşur [37]. Giriş katmanı 224x224x3 olan görüntüler için 3x3x3'lük evrişim filtreleri kullanır. Çekirdek katmanlarda ise 6 ayrı blok bulunur. Her blok 2x2'lik evrişim blokları ve arttırılmış bloklardan oluşur. Her evrişim bloğu 1x1 ve 3x3'lük evrişim filtreleri kullanarak 4x4 boyutunda bir alan için özellik çıkarır. Çıkış katmanı ise varsayılan olarak 1000 sınıf etiketi için 1000 nöronlu bir tam bağlantılı katmandır. Bu çalışmada 2 sınıf olduğu için çıkış katmanı 2 nöronlu bir tam bağlantılı katman ile değiştirilmiştir.

3.4 VGG16

VGG16 16 katmandan oluşan çok katmanlı bir sinir ağıdır [39]. 13 adet evrişim katmanı, 3 tam bağlantılı katman, 5 havuzlama katmanından oluşur. Bu 13 evrişim katmanında bulunan evrişim blokları 3x3 boyutunda 1 adım hareketine sahiptir. Evrişim çekirdeği ilk katmanda kademeli olarak 128'den 256'ya sonra 512'ye yükseltilir. Havuzlama katmanındaki evrişim blokları 2x2 ve adım boyutu 2 'dir. Yine giriş görüntüleri 224x224x3 olarak verilir. Yine çıkış boyutu 1000 sınıfa uygun 1000 nörondan oluşturulduğundan transfer öğrenme metoduyla son katmanları 2 nöronlu tam bağlantı katmanı ile değiştirilip Softmax aktivasyon fonksiyonu kullanılmıştır.

3.5 AlexNet

AlexNet mimarisi 8 katmandan oluşmaktadır; bunlar 11 x 11 çözünürlüklü birçoklu filtreli evrişim katman, 5 x 5 boyutunda bir evrişim bloğu, 3 x 3 boyutunda üç tane çoklu filtreli evrişim bloğu ve üç tane tam bağlantılı katmandır. Evrişimsel katmanlar, değişen filtre boyutları ve adım değerleri ile 13 x 13 çıkış boyutuna sahipken, tam bağlantılı katmanların çıkış boyutu 4096'dır. Son olarak, son fully

connected katmanın çıkış boyutu 1000 olacak şekilde ayarlanmıştır, böylece ImageNet veri kümesindeki 1000 farklı sınıfı temsil eder. Giriş ise 227x227x3'tür. SDDFB ısı haritası görüntüleri bu mimariye verilmek için bu boyuta uygun tekrar boyutlandırılmış ve çıkış katmanları da transfer öğrenme yöntemiyle 2 sınıf için tam bağlantılı katman oluşturularak ayarlanmıştır.


4 Bulgular ve tartışma

Tüm deneysel çalışmalar, MATLAB programı aracılığıyla gerçekleştirilmiştir. Deneysel çalışmada kullanılan bilgisayar Intel i5-12400F işlemci, 16 GB RAM ve Nvidia RTX 2080 Ti ekran kartı barındırmaktadır. Oluşturulan ısı haritası görüntüleri 224x224x3 (AlexNet için 227x227x3) olarak yeniden boyutlandırılmıştır. Görüntüler; ResNet18, ResNet50, VGG16 ve AlexNet mimarilerine verilmiştir. Tüm mimariler için optimizasyon olarak 'sgdm' kullanılmıştır. Minibatch boyutu 10 olarak ayarlanmış maksimum epoch 20 olarak seçilmiştir. Başlangıç öğrenme oranı ise 0.001 olarak ayarlanmıştır. Doğrulama frekansı 3 olarak seçilmiştir. Bu parametreler her ESA modeli için aynı seçilmiştir. Bu sayede birbirleriyle başarı oranı ve süre açısından kıyaslanabilir olacaktır. Deneysel çalışmalarda tüm veri seti 30 saniyelik parçalara bölünmüştür. 30 saniyelik parçalara ayırmadaki amaç literatürde önceden yapılmış 30 saniyelik parçalarla yapılan sınıflandırma çalışmalarıyla kendi yöntemimizi kıyaslayabilmektir. Hipertansiyon için toplamda 61525 SDDFB ısı haritası görüntüleri elde edilirken normal tansiyon için 71413 SDDFB ısı haritası görüntü elde edilmiştir. Toplamda elde edilen 132938 görüntüden 3000 hipertansiyon sınıfından 3000 normal tansiyon sınıfından rastgele seçilerek ResNet18, ResNet50, AlexNet ve VGG16 ağlarının eğitiminde kullanılmış ve sonuçlar değerlendirilmiştir. Sınıflandırmalar gerçekleşirken veri setinin %90'ı eğitim %10'u test için kullanılmıştır.

4.1 ResNet50 için sonuçlar

İlk deneme ResNet50 mimarisiyle gerçekleştirilmiştir. Eğitim süreci Şekil 6'daki gibidir. Şekilde görüldüğü gibi 20 epoch yaklaşık 117 dakika 30 saniyede tamamlanmıştır. Üçüncü epoch esnasında ezberleme durumu gözlenmiştir. Dördüncü epoch sonrasında daha stabil hale gelen eğitim %99.67'lik bir başarı oranıyla tamamlanmıştır. Eğitim %99.34 nihai başarı ile tamamlanmıştır.

ResNet50 ile gerçekleştirilen denemenin karmaşıklık matrisi ise Şekil 7'de verilmiştir. Şekilde görülen ilk iki çapraz yeşil renkli olan hücreler yapılan doğru sınıflandırmaların her iki sınıf için sayısını ve yüzdesini gösterir. Görüldüğü gibi tüm verinin 299'unu hipertansiyon olarak sınıflandırmıştır. Bu 600'ün %49.8'ine tekabül etmektedir. 299 tanesi de normal tansiyon olarak sınıflandırmıştır. Bu tüm verinin %49.8'idir. Hipertansiyonların yanlışlıkla 1 tanesini normal tansiyon olarak sınıflandırmıştır. Bu tüm verilerin %0.2'sine tekabül eder. Normal tansiyonların da yanlışlıkla 1 tanesini hipertansiyon olarak sınıflandırmıştır. Bu da tüm verinin %0.2'sidir. 300 hipertansiyon %99.7'sini doğru, %0.3'ünü ise yanlış tahmin etmiştir.



Şekil 6. 10 katlı çapraz doğrulamadaki bir deneme için ResNet50 eğitim sonucu.

300 normal tansiyonun %99.7'sini doğru, %0.3'ünü yanlış tahmin etmiştir. 300 hipertansiyonun %99.7'sini doğru bir şekilde tahmin etmiş ve %0.3'ünü de normal tansiyon olarak yanlış tahmin etmiştir. 300 normal tansiyon vakasının %99.7'sini doğru bir şekilde normal tansiyon ve %0.3'ünü ise hipertansiyon olarak yanlış sınıflandırılmıştır. Genel olarak tahminlerin %99.7'si doğru olup %0.3'ü yanlıştır.

aşırı uyum gözlenmiştir. Onuncu epoch sonrasında daha stabil hale gelen eğitim %99.00'lık bir başarı oranıyla tamamlanmıştır. Eğitim %98.92'lik nihai başarımla ile tamamlanmıştır.

ResNet18 ile gerçekleştirilen denemenin karmaşıklık matrisi ise Şekil 9'da verilmiştir. Şekilde görülen ilk iki çapraz yeşil renkli olan hücreler yapılan doğru sınıflandırmaların her iki sınıf için sayısını ve yüzdesini gösterir. Görüldüğü gibi tüm verinin 299'unu hipertansiyon olarak sınıflandırmıştır. Bu verinin tamamının %49.8'ine tekabül etmektedir. 295 tanesi de normal tansiyon olarak sınıflandırmıştır. Bu ise tüm verinin %49.2'sidir. Hipertansiyonların yanlışlıkla 5 tanesini normal tansiyon olarak sınıflandırmıştır. Bu tüm verilerin %0.8'ine tekabül eder. Normal tansiyonların da yanlışlıkla 1 tanesini hipertansiyon olarak sınıflandırmıştır. Bu da tüm verinin %0.2'sidir. 304 hipertansiyon %98,4'ünü doğru, %1.6'sını ise yanlış tahmin etmiştir. 296 normal tansiyonun %99.7'sini doğru, %0.3'ünü yanlış tahmin etmiştir. 300 hipertansiyonun %99.7'sini doğru bir şekilde tahmin etmiş ve %2.6'sını da normal tansiyon olarak yanlış tahmin etmiştir. 300 normal tansiyon vakasının %98.3'ünü doğru bir şekilde normal tansiyon ve %2.1'i ise hipertansiyon olarak yanlış sınıflandırılmıştır. Genel olarak tahminlerin %99.0'ı doğru olup %1 i yanlıştır.

		Confusion Matrix		
		hiper,mg	nonhiper,mg	
Output Class	hiper,mg	299 49.8%	1 0.2%	99.7% 0.3%
	nonhiper,mg	1 0.2%	299 49.8%	99.7% 0.3%
		hiper,mg	nonhiper,mg	99.7% 0.3%
		Target Class		99.7% 0.3%


Şekil 7. 10 KÇD'deki bir deneme için ResNet50 karmaşıklık matrisi

4.2 ResNet18 için sonuçlar

ResNet18 için eğitim süreci Şekil 8'deki gibidir. Şekilde görüldüğü gibi 20 epoch yaklaşık 50 dakika 47 saniyede tamamlanmıştır. Dördüncü ve beşinci epochlar esnasında

4.1 VGG16 için sonuçlar

VGG16 için eğitim süreci Şekil 11'deki gibidir. Şekilde görüldüğü gibi 20 epoch yaklaşık 207 dakika 22 saniyede tamamlanmıştır. Dördüncü, beşinci, sekizinci ve on beşinci epochların sonlarında aşırı uyum gözlenmiştir. On beşinci epoch sonrasında daha stabil hale gelen eğitim %99.50'lık bir başarı oranıyla tamamlanmıştır. Eğitim %99.22'lik nihai başarımla ile tamamlanmıştır.



Şekil 8. 10 katlı çapraz doğrulamadaki bir deneme için ResNet18 eğitim sonucu

Confusion Matrix			
Output Class	hiper,mg	nonhiper,mg	
hiper,mg	299 49.8%	5 0.8%	98.4% 1.6%
nonhiper,mg	1 0.2%	295 49.2%	99.7% 0.3%
	99.7% 0.3%	98.3% 1.7%	99.0% 1.0%
	hiper,mg	nonhiper,mg	
	Target Class		

Şekil 9. 10 KÇD'deki bir deneme için ResNet18 karmaşıklık matrisi


VGG16 ile gerçekleştirilen denemenin karmaşıklık matrisi ise Şekil 12'de verilmiştir. Şekilde görülen ilk iki çapraz yeşil renkli olan hücreler yapılan doğru sınıflandırmaların her iki sınıf için sayısını ve yüzdesini gösterir. Görüldüğü üzere tüm verinin 300'ünü hipertansiyon olarak sınıflandırmıştır. Bu 600'ün %50'sine tekabül etmektedir. 297 tanesi de normal tansiyon olarak sınıflandırmıştır. Bu tüm verinin %49.5'idir. Hipertansiyonların yanlışlıkla 3 tanesini normal tansiyon olarak sınıflandırmıştır. Bu tüm verilerin %0.5'ine tekabül eder. Normal tansiyonların da hiçbiri hipertansiyon olarak sınıflandırılmamıştır. 303 hipertansiyon %99'ünü doğru,

%1'ini ise yanlış tahmin etmiştir. 297 normal tansiyonun %100'ünü doğru tahmin etmiştir. 300 hipertansiyonun %100'ünü doğru bir şekilde tahmin etmiştir. 297 normal tansiyon vakasının %100'ünü doğru bir şekilde normal tansiyon olarak doğru sınıflandırmıştır. Genel olarak tahminlerin %99.5'i doğru olup %0.5'i yanlıştır.

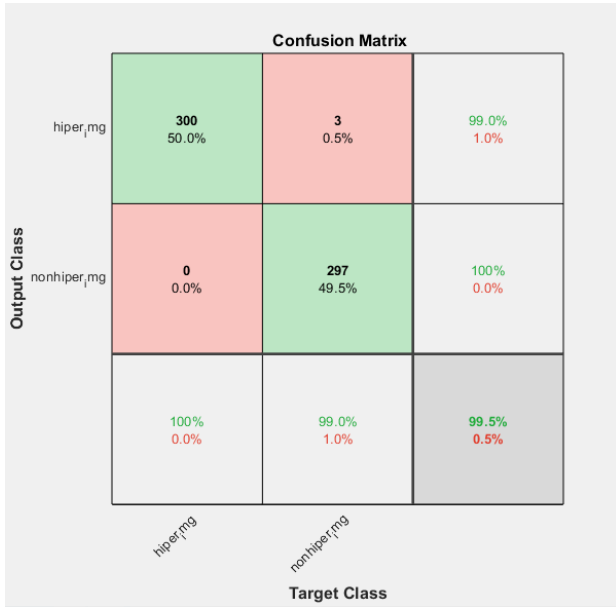
4.2 AlexNet için sonuçlar

AlexNet için eğitim süreci Şekil 13'deki gibidir. Şekilde görüldüğü gibi 10 KÇD'deki 1 denemedeki 20 epoch yaklaşık 40 dakika 58 saniyede tamamlanmıştır. Eğitimdeki bir deneme %98.17'lik bir başarı oranıyla tamamlanmıştır. Eğitim %98.03'lük nihai başarımla tamamlanmıştır.

AlexNet ile gerçekleştirilen denemenin karmaşıklık matrisi ise Şekil 15'te verilmiştir. Şekilde görülen ilk iki çapraz yeşil renkli olan hücreler yapılan doğru sınıflandırmaların her iki sınıf için sayısını ve yüzdesini gösterir. Görüldüğü gibi tüm verinin 299'ünü hipertansiyon olarak sınıflandırmıştır. Bu 600'ün %49.8'ine tekabül etmektedir. 290 tanesi de normal tansiyon olarak sınıflandırmıştır. Bu tüm verinin %48.3'üdür. Hipertansiyonların yanlışlıkla 10 tanesini normal tansiyon olarak sınıflandırmıştır. Bu tüm verilerin %1.7'sine tekabül eder. Normal tansiyonların da yanlışlıkla 1 tanesini hipertansiyon olarak sınıflandırmıştır. Bu da tüm verinin %0.2'sidir. 310 hipertansiyon %96.8'ini doğru, %3.2'sini ise yanlış tahmin etmiştir. 291 normal tansiyonun %99.7'sini doğru, %0.3'ünü yanlış tahmin etmiştir. 300 hipertansiyonun %99.7'sini doğru bir şekilde tahmin etmiş ve %0,3'ünü de normal tansiyon olarak yanlış tahmin etmiştir. 300 normal tansiyon vakasının %96.7'sini doğru bir şekilde normal tansiyon ve %1.7'isini ise hipertansiyon olarak yanlış sınıflandırılmıştır. Genel olarak tahminlerin %98.2'si doğru olup %1.8'i yanlıştır.



Şekil 10. 10 katlı çapraz doğrulamadaki bir deneme için VGG16 eğitim sonucu



Şekil 12. 10 KÇD'deki bir deneme için VGG16 karmaşıklık matrisi


Tablo 2'de görüldüğü üzere en iyi sınıflandırma sonucunu %99.34 ile ResNet50 modeli ortaya koymuştur. VGG16 modeli de %99.22 ile %98.92 başarı oranı yakalayan ResNet18 e göre daha iyi sınıflandırma sonucu vermiştir. Süre olarak en kısa sürede eğitim gerçekleştiren mimari AlexNet mimarisidir. Fakat en düşük sınıflandırma başarısını AlexNet vermiştir. ResNet18 mimarisi ise ResNet50'ye göre daha hızlıdır.

Tablo 2 Ortalama sınıflandırma başarıları ve süreleri

ESA Modeli	Sınıflandırma Başarısı (%)	Süre (Saniye)
ResNet 18	98.92	3047
ResNet 50	99.34	7050
VGG16	99.22	12442
AlexNet	98.07	2458

5 Bulgular ve tartışma

Bu çalışmada, BKG sinyallerine dayalı olarak hipertansiyonu otomatik olarak tanımak için yeni bir yöntem geliştirilmiştir. Bir dizi ön işleme uygulanmıştır. Uygulanan ön işleme teknikleri metodoloji kısmında anlatılmıştır. BKG sinyalleri, SDDFB tekniğine dayalı olarak zaman-frekans ısı haritaları görüntülerine dönüştürüldü. Çalışmanın sınıflandırma aşamasında ResNet18, ResNet50, VGG16 ve AlexNet mimarileri kullanılmıştır. Geliştirilen modelin sonuçları karmaşıklık matrisi ile değerlendirilmiştir. 10 KÇD kullanılarak gerçekleştirilen çalışma ResNet50 modeli için %99.34 sınıflandırma başarısı elde etti. Tablo 3'de aynı veri kümesi kullanılarak yapılan çalışmalar ile yaptığımız çalışmayı kıyasladık. Tabloda görüldüğü üzere birçok araştırmacı da hipertansiyonu otomatik olarak tanımak için makine öğrenmesi ve derin öğrenme yöntemlerini kullanmıştır. Şimdiye kadar ki en iyi doğruluk oranı %97.69 ile kendi yaptığımız bir önceki çalışmadır [25]. Yine [21] 'de %97.65 ile yüksek bir doğruluk oranı elde etmiştir.



Şekil 13. 10 katlı çapraz doğrulamadaki bir deneme için AlexNet için eğitim sonucu

Tablo 3. Önerilen çalışmanın performans karşılaştırması, benzer BKG veri seti kullanılarak yapılan son teknoloji çalışmalarla yapılmıştır

Yazarlar	Özellik/Yöntem	Sınıflandırıcı	Veri Seti	Performans (%)
Song vd. [18]	KAHD zamanı / KAA, Trendsiz dalgalanma analizi	Naïve Bayes	Kendi veri setleri (18 katılımcı)	92.3
Liu vd. [19]	KAHD zamanı, Frekans alanı özellikleri, Örnek entropi, BKG dalgalanma özellikleri	Lib Destek Vektör Makineleri, Karar ağacı, Naïve Bayes	Kendi veri setleri (128 katılımcı)	84.4 Doğruluk 82.5 Kesinlik 85.3 Hatırlama
Rajput vd. [20]	Kosinüs dalgacık dönüşüm skalogram	2-B ESA	[19]'daki veri seti	86.14
Gupta vd. [21]	Ayarlanabilir Q faktörü dalgacık dönüşümü (AQFD); Shannon Entropi, log enerji, Hjorth karmaşıklık; standart sapma, kök ortalama kare değeri; kurtosis; çarpıklık; ortalama, maksimum ve minimum değer; Kruskal-Wallis	k-EYK	[19]'daki veri seti	92.21
Gupta vd. [22]	Düzeltilmiş sahte wigner wille dağılımı, Kısa zamanlı Fourier dönüşümü	Hyp-Net (ESA)	[19]'daki veri seti	97.65
Seok vd. [23]	AMA ile Hilbert dönüşümü	ESA-Regresyon	Kendi veri setleri (30 katılımcı)	sistolik kan basıncı için 6.24 standart sapma, diastolik kan basıncı için 5.42 standart sapma
Rajput vd. [24]	AMA, DD	Grup yumuşak artırıcı sınıflandırıcı, destek vektör makineleri (DVM), EYK, karar ağacı	[19]'daki veri seti	89
Ozcelik vd. [25]	İnce ayarlı spektrogram görüntüleri ve ConvMixer mimarisi	ConvMixer (ESA)	[19]'daki veri seti	97.69
Önerilen Yöntem	SDDFB ısı haritası görüntüleri ve ESA mimarileri	ESA	[19]'daki veri seti	99.34

		Confusion Matrix		
		hiper,mg	nonhiper,mg	
Output Class	hiper,mg	299 49.8%	10 1.7%	96.8% 3.2%
	nonhiper,mg	1 0.2%	290 48.3%	99.7% 0.3%
		hiper,mg	nonhiper,mg	
		99.7% 0.3%	96.7% 3.3%	98.2% 1.8%

Şekil 14. 10 KÇD'deki bir deneme için AlexNet karmaşıklık matrisi

[20] ve [24]'te çalışmamızdaki gibi çeşitli dalgacık dönüşümü tabanlı öznelikleri kullandılar ve sırasıyla %86.14 ve %89 doğruluk puanları elde ettiler. Biz bu çalışmada %99.34 ile en yüksek sınıflandırma başarısı elde ettik.

Bu çalışmanın sağladığı bazı avantajlar aşağıdaki gibidir:

- BKG sinyalleri kullanılarak hipertansiyon tespiti için basit, doğru ve verimli bir model geliştirildi.
- SDDFB yönteminin etkinliği ortaya koyulmuş. Diğer dalgacık yöntemlerine göre etkinliği ortaya koyulmuştur.
- ResNet18, ResNet50, AlexNet ve VGG16 mimarileri hız ve performans açısından karşılaştırılmıştır.

6 Sonuçlar

Bu çalışmada BKG sinyalleri kullanılarak otomatik hipertansiyon tespiti için başarılı ve hesaplama açısından daha az karmaşık bir yaklaşım geliştirilmiştir. Önerilen yaklaşımda, giriş BKG sinyalleri başlangıçta segmentlere ayrılmış ve filtrelenmiştir. Ardından, sinyalleri ısı haritası görüntülerine dönüştürmek için SDDFB yaklaşımı kullanılmıştır. Sınıflandırma amacıyla ResNet50, ResNet18, AlexNet ve VGG16 kullanılmıştır. Bu çalışmanın kısıtlılığı, sadece 128 (61 HPT ve 67 normal) kişilik bir veri seti kullanmış olmamızdır. Gelecekteki çalışmalarda daha fazla kişiden oluşan bir veri seti kullanmayı ve modelimizi doğrulamayı planlıyoruz.

Ayrıca, SDDFB yöntemi için elektroensefalogram (EEG), elektromiyogram (EMG) vb. fizyolojik sinyalleri kullanan çeşitli sağlık uygulamalarında kullanılabilir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %10

Burada makalenin benzerlik oranı beyan edilmelidir.

Kaynaklar

- [1] A. N. Desai, High Blood Pressure. JAMA. 324(12):1254–1255, 2020. <https://doi.org/10.1001/jama.2020.11289>
- [2] M. Vaduganathan, G. Mensah and J. Turco, The Global Burden of Cardiovascular Diseases and Risk. J Am Coll Cardiol. 80(25), 2361–2371, 2022. <https://doi.org/10.1016/j.jacc.2022.11.005>
- [3] B. Zhou, R. M. Carrillo-Larco, G. Danaei, L. M. Riley, C. J. Paciorek, G. A. Stevens and J. Breckenkamp, Worldwide trends in hypertension prevalence and progress in treatment and control from 1990 to 2019: a pooled analysis of 1201 population-representative studies with 104 million participants. The Lancet, 398(10304), 957-980, 2021. [https://doi.org/10.1016/S0140-6736\(21\)01330-1](https://doi.org/10.1016/S0140-6736(21)01330-1)
- [4] R. M. Carey and P. K. Whelton, 2017 ACC/AHA Hypertension Guideline Writing Committee*. Prevention, detection, evaluation, and management of high blood pressure in adults: synopsis of the 2017 American College of Cardiology/American Heart Association Hypertension Guideline. Annals of internal medicine, 168(5), 351-358,2018. <https://doi.org/10.7326/M17-3203>
- [5] M. D. Zink, C. Brüser, B. O Stüben, A. Napp, R. Stöhr, S. Leonhardt and J. Schiefer, Unobtrusive nocturnal heartbeat monitoring by a ballistocardiographic sensor in patients with sleep disordered breathing. Scientific reports, 7(1), 1-13, 2017. <https://doi.org/10.1038/s41598-017-13138-0>
- [6] O. T. Inan, P. F. Migeotte, K. S. Park , M. Etemadi, K. Tavakolian, R. Casanella, and M. Di Rienzo, Ballistocardiography and seismocardiography: A review of recent advances. IEEE journal of biomedical and health informatics, 19(4), 1414-1427,2014. <https://doi.org/10.1109/JBHI.2014.2361732>.
- [7] M. D. Zink, C. Brüser, P. Winnersbach, A. Napp, S. Leonhardt, N. Marx and K. Mischke, Heartbeat cycle length detection by a ballistocardiographic sensor in atrial fibrillation and sinus rhythm. BioMed research international,2015.<https://doi.org/10.1155/2015/840356>
- [8] K. S. Parmar, A. Kumar and U. Kalita, ECG signal based automated hypertension detection using fourier decomposition method and cosine modulated filter banks. Biomedical Signal Processing and Control, 76, 103629, 2022. <https://doi.org/10.1016/j.bspc.2022.103629>
- [9] A. L. Goldberger, L. A. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark and H. E. Stanley, PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. Circulation, 101(23), 215-220, 2000. <https://doi.org/10.1161/01.CIR.101.23.e215>
- [10] G. B. Moody, R. G. Mark and A. L. Goldberger, PhysioNet: Physiologic signals, time series and related open source software for basic, clinical, and applied

- research. In 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society 8327-8330,2011. <https://doi.org/10.1109/IEMBS.2011.6092053>
- [11] D. C. K. Soh, E. Y. K. Ng, V. Jahmunah, , S. L. Oh, San R. Tan and U. R. Acharya, Automated diagnostic tool for hypertension using convolutional neural network. *Computers in Biology and Medicine*, 126, 103999,2020. <https://doi.org/10.1016/j.combiomed.2020.103999> .
- [12] J. S. Rajput, M. Sharma and U. R. Acharya. Hypertension diagnosis index for discrimination of high-risk hypertension ECG signals using optimal orthogonal wavelet filter bank. *International journal of environmental research and public health*, 16(21), 4068, 2019. <https://doi.org/10.3390/ijerph16214068>.
- [13] A. Ari, F. Ayaz ve D. Hanbay. EMG sinyallerinin kısa zamanlı fourier dönüşüm özellikleri kullanılarak yapay sinir ağları ile sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(2), 443-451, 2019. <https://doi.org/10.35234/fumbd.545161>
- [14] Ari, A. (2020). Analysis of EEG signal for seizure detection based on WPT. *Electronics Letters*, 56(25), 1381-1383. <https://doi.org/10.1049/el.2020.2701>
- [15] M. Turkoglu, M. Aslan, A. Ari , Z. M. Alçin & D. Hanbay. A multi-division convolutional neural network-based plant identification system. *PeerJ Computer Science*, 7, e572, 2021. <https://doi.org/10.7717/peerj-cs.572>
- [16] Donuk, K., Ari, A., & Hanbay, D. A CNN based real-time eye tracker for web mining applications. *Multimedia Tools and Applications*, 81(27), 39103-39120, 2022. <https://doi.org/10.1007/s11042-022-13085-7>
- [17] A. Ari, Multipath feature fusion for hyperspectral image classification based on hybrid 3D/2D CNN and squeeze-excitation network. *Earth Science Informatics*, 1-17,2023, <https://doi.org/10.55525/tjst.1261887> .
- [18] Y. Song , H. Ni, X. Zhou, W. Zhao and T. Wang, Extracting features for cardiovascular disease classification based on ballistocardiography. In 2015 IEEE 12th Intl Conf on Ubiquitous Intelligence and Computing and 2015 IEEE 12th Intl Conf on Autonomic and Trusted Computing and 2015 IEEE 15th Intl Conf on Scalable Computing and Communications and Its Associated Workshops (UIC-ATC-ScalCom), pp. 1230-1235, Beijing, China, August 2015.
- [19] F. Liu, X. Zhou, , Z. Wang, J. Cao, H. Wang and Y. Zhang, Unobtrusive mattress-based identification of hypertension by integrating classification and association rule mining. *Sensors*, 19(7), 1489, 2019. <https://doi.org/10.3390/s19071489>
- [20] J. S. Rajput, M. Sharma , T. S. Kumar and U. R. Acharya. Automated detection of hypertension using continuous wavelet transform and a deep neural network with Ballistocardiography signals. *International Journal of Environmental Research and Public Health*, 19(7), 4014, 2022. <https://doi.org/10.3390/ijerph19074014>.
- [21] K. Gupta, V. Bajaj and I. A. Ansari, A support system for automatic classification of hypertension using BCG signals. *Expert Systems with Applications*, 214, 119058, 2023. <https://doi.org/10.1016/j.eswa.2022.119058>.
- [22] K. Gupta, V. Bajaj , I. A. Ansari and U. R. Acharya, Hyp-Net: Automated detection of hypertension using deep convolutional neural network and Gabor transform techniques with ballistocardiogram signals. *Biocybernetics and Biomedical Engineering*, 42(3), 784-796,2022. <https://doi.org/10.1016/j.bbe.2022.06.001>.
- [23] W. Seok, K. J. Lee, D. Cho, J. Roh and S. Kim, Blood pressure monitoring system using a two-channel ballistocardiogram and convolutional neural networks. *Sensors*, 21(7), 2303, 2021. <https://doi.org/10.3390/s21072303>
- [24] J. S. Rajput, M. Sharma, D. Kumbhani and U. R. Acharya, Automated detection of hypertension using wavelet transform and nonlinear techniques with ballistocardiogram signals. *Informatics in Medicine Unlocked*, 26, 100736, 2021. <https://doi.org/10.3390/s21072303>.
- [25] S. T. Ozcelik, H. Uyanık, , E. Deniz and A. Sengur, Automated Hypertension Detection Using ConvMixer and Spectrogram Techniques with Ballistocardiograph Signals. *Diagnostics*, 13(2), 182, 2023. <https://doi.org/10.3390/diagnostics13020182>.
- [26] I. S. Chang, J. Boger, S. Mak, S. L. Grace, A. Arcelus, C. Chessex and A. Mihailidis, Load Distribution Analysis for Weight and Ballistocardiogram Measurements of Heart Failure Patients using a Bed Scale. In 2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC) pp. 7369-7372, Mexico, November 2021.
- [27] M. Köseoğlu and H. Uyanık, Effect of Spectrogram Parameters and Noise Types on The Performance of Spectro-temporal Peaks Based Audio Search Method. *Gazi University Journal of Science*, 2022. <https://doi.org/10.35378/gujs.1000594>
- [28] M. Köseoğlu, & H. Uyanık, The Effect of Different Noise Levels on The Performance of The Audio Search Algorithm. In 2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA) pp. 1-7, Ankara, Turkey, June 2020.
- [29] H. Uyanık, & M. Köseoğlu, Performance Evaluation of Different Window Functions for Audio Fingerprint Based Audio Search Algorithm. In 2020 4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), pp. 1-4, Ankara, Turkey, October 2020.
- [30] D. Şengür, & S. Siuly, Efficient approach for EEG-based emotion recognition. *Electronics Letters*, 56(25), 1361-1364, 2020. <https://doi.org/10.1049/el.2020.2685>.

- [31] H. Uyanık, S. T. A. Ozcelik, Z. B. Duranay , A. Sengur, & U. R. Acharya , Use of Differential Entropy for Automated Emotion Recognition in a Virtual Reality Environment with EEG Signals. *Diagnostics*, 12(10), 2508,2022.<https://doi.org/10.3390/diagnostics12102508>.
- [32] Ari, B., Sobahi, N., Alçin, Ö. F., Sengur, A., & Acharya, U. R. (2022). Accurate detection of autism using Douglas-Peucker algorithm, sparse coding based feature mapping and convolutional neural network techniques with EEG signals. *Computers in Biology and Medicine*, 143, 105311 <https://doi.org/10.1016/j.combiomed.2022.105311> .
- [33] Sobahi, N., Ari, B., Cakar, H., Alcin, O. F., & Sengur, A. (2022). A new signal to image mapping procedure and convolutional neural networks for efficient schizophrenia detection in eeg recordings. *IEEE Sensors Journal*, 22(8), 7913-7919 <https://doi.org/10.1109/JSEN.2022.3151465> .
- [34] Ari, B., Siddique, K., Alçin, Ö. F., Aslan, M., Şengür, A., & Mehmood, R. M. (2022). Wavelet ELM-AE Based Data Augmentation and Deep Learning for Efficient Emotion Recognition Using EEG Recordings. *IEEE Access*, 10, 72171-72181 <https://doi.org/10.1109/ACCESS.2022.3181887> .
- [35] https://www.mathworks.com/help/matlab/ref/double.normalize.html#mw_dcfb89d2-e230-4be0-bb16-d672f91b8e91
- [36] J. M. Lilly, & S. C. Olhede. Higher-order properties of analytic wavelets. *IEEE Transactions on Signal Processing*, 57(1), 146-160, 2008. <https://doi.org/10.1109/TSP.2008.2007607>.
- [37] K. He, X. Zhang, S. Ren and J. Sun, Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770-778, Las Vegas, USA, June 2016.
- [38] K. He, X. Zhang, S. Ren and J. Sun, Identity mappings in deep residual networks. In *European conference on computer vision*, pp. 630-645, Amsterdam, Netherlands, October, 2016.
- [39] K. Simonyan and A. Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014. <http://doi.org/10.48550/arXiv.1409.1556>

