



## Radar Teknolojisi ile Hayati Sinyallerin Tespitinde Geç Füzyon Tabanlı Evrışimsel Sinir Ağı Modeli

### Late Fusion Based Convolutional Network Model in Detection of Vital Signals with Radar Technology

Umut Özkaya<sup>1\*</sup>

<sup>1</sup>Department of Electric-Electronic-Engineering, Engineering and Natural Science Faculty, Konya Technical Univ., Konya, Turkey.

**Başvuru/Received:** 10/01/2023

**Kabul / Accepted:** 25/01/2023

**Çevrimiçi Basım / Published Online:** 31/01/2023

**Son Versiyon/Final Version:** 31/01/2023

#### Öz

Bu çalışmada hayati sinyallerin sınıflandırılması için Evrışimsel Sinir Ağları (ESA) ve füzyon teknolojisine dayalı bir yöntem önerildi. Tek boyutlu radar sinyallerinden daha fazla bilgi edinmek amacıyla spektrogram tekniği ile 2 boyutlu veriler elde edildi. GoogleNet, VGG-16 ve ResNet-50 ön eğitilmiş ESA kullanılarak otomatik bir sınıflandırma çerçevesi uygulanmıştır. En yüksek performansa sahip VGG-16 ve GoogleNet ESA yapılarına geç füzyon işlemi uygulanarak test verilerindeki performans artırılmıştır. Önerilen yöntemin performans 92.54% Doğruluk (DOĞ), 92.41% Duyarlılık (DUY), 97.18% Özgüllük (ÖZG), 93.54% Hassasiyet (HAS), 92.66% F1-Skoru ve 90.25% Matthews Korelasyon Sabiti (MKS)'dir. Önerilen yöntem sayesinde tahribatsız algılama teknolojilerinden biri olan radar teknolojisi giyilebilir teknolojilere göre daha ön plana çıkmaktadır.

#### Anahtar Kelimeler

*Radar, Hayati Sinyal, Derin Öğrenme, Evrışimsel Sinir Ağları, Geç Füzyon*

#### Abstract

In this study, a method based on Convolutional Neural Networks (CNN) and fusion technology was proposed for the classification of vital signals. In order to obtain more information from 1-D radar signals, 2-D data were obtained with the spectrogram technique. An automated classification framework has been implemented by using pre-trained Google Net, VGG-16 and ResNet-50 models. The performance in the test data is increased by applying late fusion process to the highest performing VGG-16 and GoogleNet CNN structures. The performance of the proposed method is 92.54% Accuracy (ACC), 92.41% Sensitivity (SEN), 97.18% Specificity (SPE), 93.54% Precision (PRE), 92.66% F1-Score, and 90.25% Matthews Correlation Constant (MCC). Thanks to the proposed method, radar technology, which is one of the non-destructive detection technologies, comes to the forefront compared to wearable technologies.

#### Key Words

*Radar, Vital Sign, Deep Learning, Convolutional Neural Network, Late Fusion*

## 1. Giriş

Obstrüktif Uyku Apne Sendromu (OUAS) dünya çapında görülen bir ölümcül hastalık olup kadınlara nazaran erkek bireylerde uyku bozukluğuna daha çok rastlanmaktadır (Young ve diğ., 1993). OUAS, uyku esnasında bireyin üst hava yolundaki hava akımının kesilmesi ile ortaya çıkar. Ayrıca birey yaşantısının her evresinde belirtilerini gösterme ihtimali bulunmaktadır. İstatistiklerden elde edilen bilgiye göre erkeklerin OUAS rahatsızlığına yakalanma oranı kadınlara göre iki kat fazla olduğu görülmektedir (Leung ve diğ., 2001). OUAS kronik bir rahatsızlık olmasıyla birlikte iskemik kalp hastalığı, artan inme prevalansı, koroner arter hastalığı, Atriyal Fibrilasyon (AF), Kronik Kalp Yetmezliği (KKY) ve kardiyak ani ölüm gibi durumları da tetiklemektedir (Seicean ve diğ., 2013). OUAS rahatsızlığının tetiklenmesini bireydeki kolesterolün artması, hipertansiyon ve tip-2 diyabet gibi etkenler olduğu düşünülmektedir. Bunun yanı sıra OUAS, vücut içerisinde oksijen desatürasyonları, oksidatif stres, kan basıncı, kalp hızı değişiklikleri ve kesintiye uğramış uykuya sebebiyet verdiği ön görülmektedir (Nieto ve diğ., 2012).

OUAS rahatsızlığının tespiti, gece boyunca bireyin bir takım aktivitelerinin polisomnografi cihazı ile izlenmesi ile mümkün olabilmektedir. Polisomnografi sistemi teşhis aşamasında güvenilirlik ve kalite bakımından tercih edilmesine rağmen bireylere sınırlı hareket imkanı sağladığından uzun süreli ve sürekli takibi olumsuz etkilemektedir. Hasta vücudunda birtakım tahriş ve lekelerin oluşmasına sebebiyet verebilmektedir (Lie ve diğ., 2011). Polysomnography izleme tekniğinin bu dezavantajları temassız ölçüm ve takip sistemlerine talebin artmasına yol açmıştır.

Bireyin yaşamsal faaliyetlerinin temassız olarak takip edilebilmesi 1970'li yıllarda Doppler radarlar sayesinde gerçekleştirilebileceği keşfedildi. İlk olarak literatürde temassız olarak solunum ve kalp atım hızlarının değerlendirilmesi üzerine yayınlar ortaya çıktı. Sonrasında ise ideal olmayan ortam şartlarında OUAS sendromunun temassız olarak tespit edebileceği kanıtlandı.

Temassız ölçüm sistemlerinde doğru bir ölçüm elde edebilmek arka plan dağınıklığı, fazsız veya sıfır noktası, DC ofsetleri, hareket artefaktları ve elektromanyetik parazitler gibi etkenlere bağlıdır (Kagawa ve diğ., 2013). Bunun yanı sıra temassız uyku izleme sistemlerinin çalışabilirliğini ortam karmaşıklığı, öngörülemez vücut hareketliliği, arka plan gürültüsü, uyku pozisyon farklılığı ve istenmeyen harmonikler olumsuz bir şekilde etkilemektedir (Kagawa ve diğ., 2011).

Literatürde, Wang ve arkadaşları solunum ve kalp atış hızını analiz etmek için WiFi cihazlarındaki faz farkı verilerini incelemişlerdir (Wang ve diğ., 2017). Quaiyum ve arkadaşları çalışmalarında simülasyon ortamında radar sistemi ile farklı insan hareketlerini tespit etmeye çalışmışlardır (Quaiyum ve diğ., 2018). Saluja ve arkadaşları kalp atışının temassız olarak tespitinde oluşan doğrusal olmayan harmonikleri, makine öğrenmesi yöntemi olan gama filtresi ile elimine ederek doğru bir şekilde ölçüm sağlamıştır (Saluja ve diğ., 2018). Erdoğan ve arkadaşları hayati işaretlerin tespitinde 24 GHz mikrodalga Doppler radar sensörü kullanmışlardır. Elde edilen sonuçların solunum kemeri ile elde edilen sonuçlar ile uyum içerisinde olduğu gözlemlenmiştir (Erdoğan ve diğ., 2019). Saluja ve arkadaşları çalışmalarında 5.8 GHz'lik Doppler radar sinyallerindeki harmonikleri denetimli bir gama filtresi ile elimine etmişlerdir (Saluja ve diğ., 2020). Chang ve arkadaşları hayati sinyalin tahmininde derin öğrenme tabanlı Newtonize Ortogonal Eşleştirme Takibi algoritması kullanmışlardır. Önerilen yöntem hem simülasyon hem de gerçek ölçüm verilerinde gösterdiği başarı ile mevcut sistemlere göre üstünlüğünü göstermektedir (Chang ve diğ., 2020). Lai yapmış olduğu çalışmada 24 GHz Doppler radar ile elde edilen hayati işaretlerin tespitinde Derin Sinir Ağları kullanmıştır (Lai ve diğ., 2020). Baldoumas ve arkadaşları çalışmada electrokardiogram ve radar sinyallerinden ortak özellik çıkararak kalp atış sinyallerini %90.82 ile sınıflayabilmektedir (Baldoumas ve diğ., 2021). Cardillo ve arkadaşları radar kendi kendine hareket etkilerini azaltarak hayati sinyallerin tespiti için yeni bir yöntem çerçevesi önermişlerdir. Bu sayede küçük ve büyük çaplı hareketler tespit edilebilmektedir (Cardillo ve diğ., 2021). Slapnicar ve arkadaşları temaslı ve temassız yöntemler ile hayati sinyallerin tespiti için derin öğrenme modeli tasarlamışlardır. Önerilen yöntem ile temaslı ölçümlerde %88, temassız ölçümlerde %83 ve füzyon işlemleri ile %88 doğruluk oranı elde etmişlerdir (Slapničar ve diğ., 2021). Savage ve arkadaşları örüntü tanıma tekniklerinden faydalanarak 75 hasta bireyden elde edilen hayati sinyalleri değerlendirmişlerdir. Sonuç olarak 85.8% doğruluk, 70% duyarlılık ve 89% özgüllük performans metrikleri elde etmişlerdir (Savage ve diğ., 2016). Tran ve arkadaşları geliştirmiş oldukları uzaktan algılama özelliği olan biyosensor ile kalp atış hızını %91.29 bir doğruluğa ulaşmışlardır (Tran ve diğ., 2015). Zaffaroni ve arkadaşları PSG verileri üzerine SleepMinder'in AHI tahmini ile 89% duyarlılık ve 94% özgüllük elde etmiştir (Zaffaroni ve diğ., 2015).

Bu çalışmada OUAS için geç veri füzyonu tabanlı Evrişimsel Sinir Ağı (ESA) mimarisi önerilmiştir. Bu kapsamda derin öğrenme algoritmaları için oldukça az olan veri miktarı için yüksek performans elde edilmesi amaçlanmıştır. Bu konu ile ilgili olarak literatürde ESA mimarilerinin eğitimi için büyük ve yeterli miktarda verinin gerektiği belirtilmiştir. Önerilen yöntemde Googlenet ve VGG-16 ESA modelleri ile elde edilen yüksek kalitedeki özellikler üzerinde geç veri füzyon işlemi gerçekleştirilmiştir. Önerilen yöntemin katkıları şu şekilde özetlenebilir:

- Önerilen yöntem sayesinde daha az örnek içeren veri kümeleri için yüksek sınıflandırma performansı elde edilir.
- Uçtan uca eğitim için uygundur.
- Mevcut son teknoloji yöntemlere göre daha etkin performans gösterir.


## 2. Materyal ve Yöntem

### 2.1. Radar Çalışma Prensibi

Sistemin içerisindeki Altı-Port yapısının en önemli özelliklerinden biri yüksek faz çözünürlüğüne sahip olmasıdır. Alıcı ve verici antenlerinin önünde gerçekleşen bir hareket  $\Delta\phi$  şeklinde bir faz değişimine neden olur. Cismin gerçekleştirmiş olduğu yer değişim miktarını  $\Delta x$ , verici anten sinyalindeki dalga boyunu  $\lambda$  kullanarak tespit edilebilir (Schellenberger S. ve diğ. 2020).

$$\Delta x = \frac{\Delta\phi \lambda}{2\pi} \quad (1)$$


Tasarlanan radar sisteminden In-Phase (I) ve Quadrature (Q) adında iki adet bileşene sahip radar ham sinyalleri elde edilir. Bu sinyaller Texas Instruments ADS1298 sayesinde anlık olarak sayısallaştırılır. I ve Q sinyalleri üzerinde arktanjan demodülasyonu yapılarak  $\Delta\phi$  hesaplanır. 2000 Hz örnekleme hızıyla sayısallaştırılan veriler XMC4500 mikro denetleyicisi kullanılarak depolanır. Kanal başına 50 örneğe ulaşıldığı anda Ethernet aracılığıyla ana bilgisayara aktarılır. Şekil 1’de radar ölçüm düzeneği yer almaktadır.



Şekil 1. Radar Ölçüm Sistemi.

### 2.2. Veri Seti Tanımlaması

Radar ölçüm işlemi belirli bir prosedür çerçevesinde gerçekleştirilmiştir. Ölçüm işleminden önce denekler en az 10 dakika dinlendirilmiştir. Ölçüm sırasında denekler ani hareketlerden kaçınımı ve normal bir şekilde nefes alıp vermeleri istenmiştir. Veri seti içerisinde toplamda dört adet sınıf bulunmaktadır. Bu sınıflar sırasıyla Dinlenme, Valsalva, Apne and Eğilme şeklindedir. Radar ölçümleri en az 10 dakika olacak şekilde gerçekleştirilmiştir. Ölçüm senaryosunun ilk başlarında Dinlenme durumu ortaya çıkmaktadır. Bu esnada denneğin kalp atım hızı 54 BPM’dir. Sonrasında belirli duraklamalar ile birlikte Valsalva üç defa gerçekleşir. Valsalva manevrası 20-21 s süreler civarında kuvvetli bir ekspirasyon olarak görülmektedir. Bu durumda denneğin dolaşım sisteminde hemodinamik değişiklikler gözlemlenir. Apne durumunda denekler nefeslerini iki durum farklı şekilde kullanmaktadırlar. İlk olarak apneden önce tamamen nefes alınır ve nefes verilir. Bu durumlar uzun süre tanımlanarak gerçekleşir. Ölçüm kapsamında Eğilme durumu iki şekilde gerçekleştirilir. Bunlar sırasıyla Yukarı ve Aşağı Eğilmedir. Yukarı eğilme işleminde denek masası eğimli bir şekilde kaldırılarak otonom sinir sistemi tetiklenmesi sağlanır. Bu durumda kan basıncı ve kalp atım hızında önemli bir değişim olur. Radar ölçüm işlemi denek masası 700’ye varıncaya dek devam eder. Sonrasında Aşağı Eğilme işlemi gerçekleştirilir. Denek masası yatay konuma gelince kadar bu işlem uygulanır. Yukarı Eğilme işleminde olduğu gibi otonom sinir sistemi aktiviteleri gerçekleşir. Şekil 2’de radar ölçüm sınıf sinyalleri yer almaktadır.



Şekil 2. Radar Ölçüm Sinyalleri.

### 2.3. Derin Öğrenme

Yapay zeka alanında son olarak ortaya çıkan derin öğrenme kavramı derin bir bilgi ağı planını temsil eder. Derin öğrenme modelleri, problemin çözümü için uzman bilgi seviyesini elde etmeyi amaçlar. Daha yüksek performansların elde edilmesi eğitim örneklerinin fazla olması ve daha derin ağların tasarlanması ile mümkündür. ESA mimarisi günümüzde çoğu problemin çözümü için kullanılır (Öztürk, 2020). ESA, farklı boyutlardaki matris veya vektör formlarını ideal bir şekilde analiz eder. Bu bölüm kapsamında daha çok 2D-ESA mimari yapılarına yer verilmektedir. ESA mimarisi farklı katmanlardan oluşur. Bu kapsamda katman özellikleri bu bölümde ele alınmıştır.

ESA mimarisinin temel katmanlarından biri evrişim katmanıdır. Mimari içerisinde farklı sayıda ve boyutta çekirdeklere sahip evrişim katmanları yer alır. Bu çekirdek parametreleri güncellenebilir özelliğe sahip olup çözülmesi istenen problem ile ilgili özellikleri öğrenir. Evrişim katmanında 2 boyutlu bir evrişim işlemi uygulanır. Bu işlemin en önemli avantajlarından biri parametre paylaşımının gerçekleştirilmesidir. Bu sayede mimarideki toplam parametre sayısında düşüş sağlanır. Havuzlama katmanı ise ESA mimarisinde kullanılan diğer önemli katmanlardan biridir. Evrişim katmanını veya Rektifiye Edilmiş Doğrusal Birim (REDB) takiben havuzlama katmanının kullanımı görülmektedir. Alt örnekleme işlemi havuzlama katmanı tarafından sağlanır. Bu çalışmada maksimum havuzlama katmanı kullanılmıştır. Diğer önemli katmanlardan biri de REDB'dir. Evrişim katmanını takiben REDB katmanının kullanımı çok sıkça rastlanır. REDB katmanı ile tasarlanan ESA mimarisinin doğrusal olmayan bir özellik kazanması amaçlanır. REDB katmanı elde edilen negatif değerleri sifıra eşitler. ESA mimarisinde yer alan tam bağlı katman klasik bir yapay sinir ağı görevi görür. ESA mimarisi ile elde edilen yüksek seviyedeki özellikler tam bağlı katmandaki düğümler ile işleme tabi tutularak sınıflama işlemi gerçekleştirilir. Temelde üç ana katmandan oluşan ESA mimarisinde hesaplamalar için aşağıdaki denklem kullanılır.

$$f(I_{sonra}) = havuzlama_{n \times n}(\sigma(w * [D_{in}] + b)) \quad (2)$$

Denklem 2'de yer alan  $I_{sonra}$  sonraki katmanlar için girdiyi temsil eder.  $havuzlama_{n \times n}$  ise  $n \times n$  boyutunda havuzlama işlemini ifade eder.  $\sigma$ ,  $w$  ve  $b$  değişkenleri REDB işlemi, evrişim çekirdeği bias değerlerini ifade eder. Sınıflama amacıyla kullanılan ağ yapılarının sonunda softmax bulunur. Denklem 3'de  $m$  sınıf için olasılıksal bir hesaplama gerçekleştirilir.

$$P_j = \frac{e^{x_j}}{\sum_1^m e^{x_m}} \quad (3)$$

ESA mimarisi için belirtilen temel katmanlara yeni katman yapıları önerilmiştir. Önerilen yöntemin açıklanabilmesi için bu katman özellikleri yeterli olacaktır. VGG-16 mimarisi toplamda 16 adet güncellenebilir ağırlıklara sahip katmanlardan oluşur (Jaderberg ve diğ., 2015). Bu katmanların 13 tanesi evrişim katmanı olup geri kalan 3 tanesi de Tam Bağlı Katman (TBK) katmanıdır. Tüm evrişim katmanları 1 adıma sahip  $3 \times 3$  boyutunda filtreler sahiptir. Havuzlama katmanları ise 2 adımda  $2 \times 2$  pencereden oluşur. İki TBK 4096 düğümden oluşurken son TBK 1000 düğümden oluşur. Toplamda 138 milyon eğitilebilir değişken yapısında bulundurulur.

Ön eğitilmiş ağlardan biri olan ResNet-50 mimarisi ek bağlantılardan oluşur. VGG-16 mimarisine göre daha derin bir yapıya sahip olmasına rağmen daha az güncellenebilir parametreler içerir. Toplamda 50 adet ağırlık katmanı yapısında bulundurulur. Son olarak 23 milyon güncellenebilir parametreye sahiptir (Fulton ve diğ., 2019).

### 2.4. Spektrogram

Sinyaldeki spektral içerik yalnızca Fourier Dönüşümü (FD) kullanılarak elde edilir. Spektrogram, sinyali küçük pencere boyutuyla zaman alanında analiz eden Kısa Zamanlı Fourier Dönüşümü (KZFD) olarak da tanımlanır. Bu işlemler Denklem 4 kullanarak gerçekleştirilir.

$$X[t, f] = \sum_{-\infty}^{\infty} x[r]. \omega[t - \tau]. e^{-j\pi\tau} \quad (4)$$

FD sadece frekans fonksiyonuna sahipken, KZFD hem frekans hem de zaman fonksiyonunu içerir. KZFD işleminden sonra elde edilen sonuç matris formundadır. FD işlemi için frekans alanında çözünürlük sorunu oluşmuyor. KZFD işleminde, sonlu boyuttaki pencerelerin kullanılması ve sinyalin parça parça analizi nedeniyle frekans alanındaki çözünürlük değişir (Giv, 2013). KZFD için küçük bir pencere seçmek, zaman alanındaki çözünürlüğü iyileştirir. Pencere büyük seçilirse, frekans alanında çözünürlük artarken, zaman alanında çözünürlük azalır.

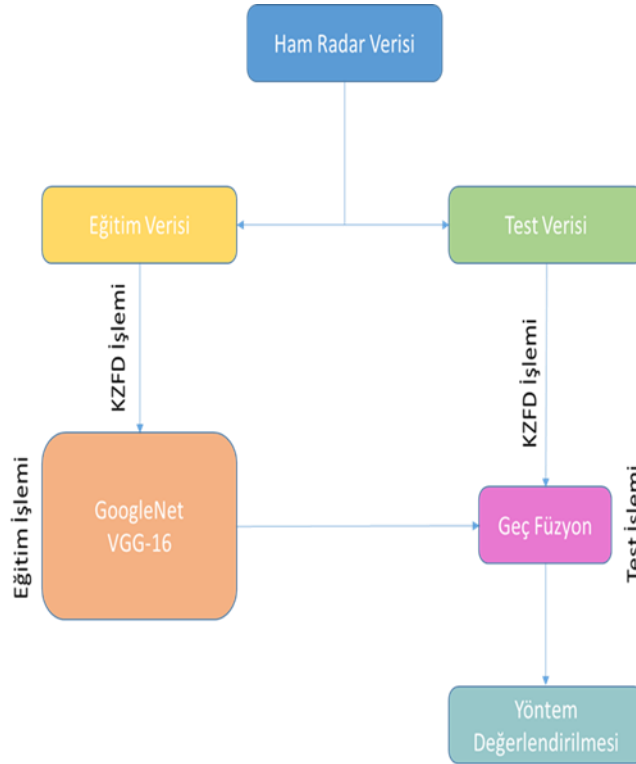
## 2.5. Geç Füzyon

Geç füzyon işleminde sınıflandırıcıların olasılıksal olarak kararını değerlendirerek gerçekleştirir. Sınıflandırıcılar, farklı ortamların özellikleri için ayrı ayrı evet/hayır gibi veya bir puan veya anlamsal bir kavramın bulunma olasılığı şeklinde bir karar vererek öğrenilir. Sınıflandırma, farklı modalitelerdeki öznitelikler farklı temsillere sahip olsa bile benzer temsile sahip kararlar elde edecek şekilde yapılmaktadır. Bağımsız kararlar, farklı kurallar kullanılarak birleştirilebilir veya çıktı puanlarından öğrenmek için sınıflandırıcılar oluşturulur.

Erken füzyondan ziyade geç füzyon işlemi karar uzayında füzyon gerçekleştirmek daha kolaydır ve verimlidir. Sınıflandırıcılardan alınan kararlar genellikle benzer formattadır. Yeni bilgi kaynaklarından alınan puanlar, yalnızca füzyon bölümünün yeniden eğitilmesiyle nihai karara kolayca eklenebilir. Ayrıca her farklı modalite türü kendi uygun sınıflandırıcısına sahip olabilir. Geç füzyon, basitliği ve ölçeklenebilirliği nedeniyle son teknolojiye yaygın olarak kullanılmaktadır.

## 2.6. Önerilen Yöntem

Ham radar sinyallerinden zaman ve frekans ortamında daha fazla bilgi sağlamak amacıyla KZFD işlemi uygulanmıştır. Bu işlemden sonra elde edilen 2-B spektrogram matrisleri farklı ön eğitilmiş ESA ağlarına girdi olarak verilmiştir. Karşılaştırmalı analiz kapsamında üç farklı ön eğitilmiş ESA ağı eğitilmiştir. Bu ağlar içerisinde en başarılı sonuçları elde eden GoogleNet ve VGG-16 modelleri önerilen yöntem çerçevesinde kullanılmıştır. Bu modeller sayesinde eğitim ve test verileri için yüksek seviyede özellikler elde edilmiştir. Bu özellikler uç uca ekleme yöntemi ile birleştirilerek daha fazla bilgi içeren özellik vektörü elde edilmiştir. Bu özellik vektörü sınıflama olasılıklarına göre geç füzyon işlemi uygulanmıştır. Sonrasında sınıflama işlemi ile tahminler gerçekleştirilmiştir. Bu özellikler geç füzyon işlemine tabi tutulmuştur. Şekil 3'de önerilen yöntem şematize edilmiştir.



Şekil 3. Önerilen Yöntem.

## 3. Bulgular ve Tartışma

Ham radar verilerinin işlenmesi, ön eğitilmiş CNN ağlarını eğitimi ve geç füzyon işlemi için 2.8 GHz hızında Intel Core i7-7700 HQ işlemci, 16 GB RAM ve NVIDIA GTX 1080 Ekran kartına sahip bir iş istasyonu kullanılmıştır. Tüm işlemlerin gerçekleştirildiği yazılım ortamı için Matlab 2020a programı seçilmiştir.

Karşılaştırmalı analizde kapsamında eğitim gerçekleştirilen ön eğitilmiş ESA ağların performansının değerlendirilmesi amacıyla 6 farklı sınıflandırma metriği kullanılmıştır. Bu ölçütler sırasıyla Doğruluk (DOG), Duyarlılık (DUY), Özgüllük (ÖZG), F1-Skoru, Hassasiyet (HAS) ve Matthews Korelasyon Sabiti (MKS)'dir. Bu metriklerin hesaplanmasında Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) indislerinden yararlanılmıştır.

$$\text{Doğruluk} = (DP + DN)/(DP + DN + YP + YN) \quad (5)$$

$$\text{Duyarlılık} = DP/(DP + YN) \quad (6)$$

$$\text{Özgüllük} = DN/(DN + YP) \quad (7)$$

$$\text{Hassasiyet} = DP/(DP + YP) \quad (8)$$

$$\text{F1 - Skoru} = (2 \times DP)/(2 \times DP + YN + YP) \quad (9)$$

$$\text{MKS} = \frac{DP \times DN - YP \times YN}{\sqrt{(DP + YP)(DP + YN)(DN + YP)(DN + YN)}} \quad (10)$$

Önerilen yöntemde kullanılan hiperparametreler ön eğitilmiş ESA ağlarına göre farklıdır. 500 Epok'a kadar eğitim gerçekleştirilmiştir. En kısa eğitim süresi 3 dak. 18 sn ile GoogleNet'e aittir. VGG-16 modeli 9 dak 55 sn ile en uzun eğitim süresine sahiptir. Karşılaştırmalı performans ölçütleri Tablo 1'de yer almaktadır.

**Tablo 1.** ESA Modellerinde Performans Karşılaştırması

Yöntem	Performans Metrikleri (%)					
	DOĞ	DUY	ÖZG	HAS	F1-SKORU	MKS
VGG-16	73,13	71,52	89,93	80,54	74,34	65,62
ResNet-50	68,66	69,23	88,45	73,41	69,64	59,42
GoogleNet	76,12	82,71	92,09	79,76	79,07	72,96
Önerilen Yöntem	<b>92,54</b>	<b>92,41</b>	<b>97,18</b>	<b>93,54</b>	<b>92,66</b>	<b>90,25</b>

Yöntemler performans açısından değerlendirildiğinde en düşük performansı ResNet-50 modeli göstermiştir. Bu model ile elde edilen sınıflandırma metrikleri 68,66% DOĞ, 69,23% DUY, 88,45% ÖZG, 73,41% HAS, 69,64% F1-Skoru ve 59,42% MKS şeklindedir. Ön eğitilmiş ağların içerisinde en yüksek performansı ise GoogleNet modelinin eğitimi ile elde edilmiştir. Performans metrikleri 76,12% DOĞ, 82,71% DUY, 92,09% ÖZG, 79,76% HAS, 79,07 F1-Skoru ve 72,96% MKS olarak bulunmuştur. Performans açısından önerilen yöntem ön eğitilmiş ESA ağlarına oldukça yüksek bir fark atmıştır. Önerilen yöntemin performans metrikleri 92,54% DOĞ, 92,41% DUY, 97,18% ÖZG, 93,54% HAS, 92,66% F1-Skoru ve 90,25% MKS'dir.

		Doğruluk				Hata		
Doğru Sınıflar	Apne	12				100%		
	Dinlenme		11	3	1	73.3%	26.7%	
	Eğilme			1	26	96.3%	3.7%	
	Valsalva					100%		
		Doğruluk				Hata		
		100%	91.7%	89.7%	92.9%			
		Hata						
				8.3%	10.3%	7.1%		
		Apne	Dinlenme	Eğilme	Valsalva			
		Tahmin Edilen Sınıflar						

**Şekil 4.** Önerilen Yöntemin Eş Oluşum Matrisi

Şekil 4'de önerilen yöntemin eş oluşum matrisindeki bulgular incelendiğinde Apne ve Valsalva sınıf doğruluğunda 100% performans sağlanmıştır. Dinlenme sınıfı için ise 73,3% doğruluk performansı elde edilmiş olup 26,7% hata oranına sahiptir. Eğilme sınıfsal doğruluğu 96,3%'dir. Hata oranı da 3,7% şeklindedir. Tablo 2 dikkate alındığında Literatürde en düşük performans Savage ve arkadaşlarına aittir. Performansı 85,8% DOĞ, 70,0% DUY ve 79,0% ÖZG şeklindedir. En yüksek performans ise Tran ve arkadaşları tarafından 91,29% DOĞ şeklinde elde edilmiştir. Önerilen yöntemin performansı diğer literatürde bulunan çalışmalara göre oldukça yüksektir. Önerilen yöntem ile 1,25% DOĞ, 3,41% DUY ve 3,18% ÖZG'lük artışı sağlanmıştır.

**Tablo 2.** Tabloda sunulan bilginin açıklaması

Yöntem	Performans Metrikleri		
	DOĞ	DUY	ÖZG
Zhang	90,82%	-	-
Slapnicar ve diğ.	88%	-	-
Savage ve diğ.	85,8%	70%	-
Tran ve diğ.	91,29%	-	-
Zaffaroni ve diğ.	-	89%	-
Önerilen Yöntem	92,54%	92,41%	93,54%

#### 4. Sonuç

Bu çalışmada temel olarak ön eğitilmiş ESA ağlarının üzerine modifikasyonlar gerçekleştirilerek yüksek performanslı radar hayatı sinyali sınıflaması yapıldı. Halka açık veri tabanında elde edilen ham radar verileri üzerinde spektrogram işlemi gerçekleştirildi. Bu sayede radar verilerinin zaman ve frekans domain araştırılmış oldu. Elde edilen 2D boyutlu radar spektrogramları ön eğitilmiş ESA ağlarının eğitim ve test işlemi için kullanıldı. En yüksek performansı gösteren VGG-16 ve GoogleNet ESA ağlarından elde edilen yüksek seviyedeki özelliklere geç füzyon işlemi uygulandı. Literatürde yer alan çalışmalara nazaran oldukça yüksek ve kayda değer sonuçlar elde edildi. Gelecekteki çalışmalarda derin öğrenme mimarilerine ek olarak attention network entegrasyonu sağlanabilir. Ayrıca farklı ölçüm cihazlarından elde edilen verilerin birleştirilmesi ile performansı artırılması ön görülmektedir.

#### Referanslar

Baldoumas G., Peschos D., Tatsis G., Christofilakis V., Chronopoulos S. K., Kostarakis P., Varotsos P. A., Sarlis N. V., Skordas E. S., Bechlioulis A., Michalis L. K., Naka K. K. (2021). Remote sensing natural time analysis of heartbeat data by means of a portable photoplethysmography device, *International Journal of Remote Sensing*, 42 (6): 2292-2302.

Cardillo E., Li C., Caddemi A. (2021). Vital sign detection and radar self-motion cancellation through clutter identification, *IEEE Transactions on Microwave Theory and Techniques*, 69 (3): 1932-1942.

Chang H., Lin C., Lin Y., Chung W., Lee T. (2020). DL-Aided NOMP: a deep learning-based vital sign estimating scheme using FMCW radar, *IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*, Antwerp, Belgium, 1-7.

Erdoğan S., Yılmaz Ş., Öncü A. (2019) Microwave noncontact vital sign measurements for medical applications, *IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, Istanbul, Turkey, 1-5.

Fulton L.V., Dolezel D., Harrop J., Yan Y., Fulton C.P. (2019). Classification of Alzheimer's disease with and without imagery using gradient boosted machines and ResNet-50, *Brain sciences*, 9 (9): 212.

Giv H.H. (2013). Directional short-time Fourier transform, *Journal of Mathematical Analysis and Applications*, 399 (1): 100-107.

Jaderberg, M., Simonyan, K., Zisserman, A. (2015). Spatial transformer networks, *Advances in neural information processing systems*, 28: 2017-2025.

Kagawa, M., Ueki, K., Tojima, H., Matsui, T. (2013). Noncontact screening system with two microwave radars for the diagnosis of sleep apnea-hypopnea syndrome, In *Proceedings of the 35th Annual International Conference of the IEEE EMBS*, Osaka, Japan, 3-7 July, 2052-2055.

Kagawa, M., Yoshida, Y., Kubota, M., Kurita, A., Matsui, T. (2011). An overnight vital signs monitoring system for elderly people using dual microwave radars, In *Proceedings of the Asia-Pacific Microwave Conference*, Melbourne, Australia, 5-8 December, 590-593.

Lai W. C. (2020). Design of receiver frontend with deep neural network for doppler radar heart rate detection, *IEEE 5th International Conference on Integrated Circuits and Microsystems (ICICM)*, Nanjing, China, 121-124.

Leung, R.S.T., Bradley, T.D. (2001). Sleep apnea and cardiovascular disease, *Am. J. Respir. Crit. Care Med.*, 164: 2147-2165.

- Lie, D.Y.C., Ichapurapu, R., Jain, S., Lopez, J., Banister, R.E., Nguyen, T., Griswold, J. A. (2011). 2.4 GHz Non-Contact biosensor system for continuous monitoring of vital-signs. In *Telemedicine Techniques and Applications*; Grasczew, G., Ed.; InTech: Rijeka, Croatia, 211–238.
- Nieto, F.J., Peppard, P.E., Young, T., Finn, L., Hla, K.M., Farré, R. (2012). Sleep-disordered breathing and cancer mortality: results from the wisconsin sleep cohort study, *Am. J. Respir. Crit. Care Med.*, 186: 190–194.
- Quaiyum F., Tran N., Phan T., Theilmann P., Fathy A. E., Kilic O. (2018). Electromagnetic modeling of vital sign detection and human motion sensing validated by noncontact radar measurements, *IEEE Journal of Electromagnetics, RF and Microwaves in Medicine and Biology*, 2 (1): 40-47.
- Öztürk Ş., (2020). Stacked auto-encoder based tagging with deep features for content-based medical image retrieval, *Expert Systems with Applications*, 161 (5).
- Saluja J. J., Lin J., Casanova J. (2018). A supervised learning approach for real time vital sign radar harmonics cancellation, *IEEE International Microwave Biomedical Conference (IMBioC)*, Philadelphia, PA, USA, 67-69.
- Saluja J., Casanova J., Lin J. (2020). A supervised machine learning algorithm for heart-rate detection using doppler motion-sensing radar, *IEEE Journal of Electromagnetics, RF and Microwaves in Medicine and Biology*, 4 (1): 45-51.
- Savage, H. O., Khushaba, R. N., Zaffaroni, A., Colefax, M., Farrugia, S., Schindhelm, K., Teschler, H., Weinreich, G., Grueger, H., Neddermann, M., Heneghan, C., Simonds, A., Cowie, M. R. (2016). Development and validation of a novel non-contact monitor of nocturnal respiration for identifying sleep-disordered breathing in patients with heart failure, *ESC Heart Failure*, 3: 212– 219.
- Schellenberger S., Shi K., Steigleder T. (2020). A dataset of clinically recorded radar vital signs with synchronised reference sensor signals, *Sci Data*, 7 (291).
- Seicean, S., Strohl, K.P., Seicean, A., Gibby, C., Marwick, T.H. (2013). Sleep disordered breathing as a risk of cardiac events in subjects with diabetes mellitus and normal exercise echocardiographic findings, *Am. J. Cardiol.*, 111: 1214–1220.
- Sindi, H., Nour, M., Rawa, M., Öztürk, Ş., Polat, K. (2021). A novel hybrid deep learning approach including combination of 1D power signals and 2D signal images for power quality disturbance classification, *Expert Systems with Applications*, 2021, 174 (114785).
- Slapničar, G., Wang W., Luštrek M. (2021). Classification of hemodynamics scenarios from a public radar dataset using a deep learning approach, *Sensors*, 21 (5): 1836.
- Tran, V. P., Al-Jumaily, A. A. (2015). Non-contact dual pulse doppler system based real-time relative demodulation and respiratory & heart rates estimations for chronic heart failure patients, *Procedia Computer Science*, 76: 47-52.
- Wang X., Yang C., Mao S. (2017). PhaseBeat: Exploiting CSI phase data for vital sign monitoring with commodity wifi devices, *IEEE 37th International Conference on Distributed Computing Systems (ICDCS)*, Atlanta, GA, USA, 1230-1239.
- Young, T., Palta, M., Dempsey, J., Skatrud, J. Webber, S. Badr, S. (1993). The occurrence of sleep-disordered breathing among middle-aged adults, *N. Engl. J. Med.*, 1 (328): 1230–1235.
- Zaffaroni, A., De Chazal, P., Heneghan, C., Boyle, P., Mppm, P. R., McNicholas, W. T. (2009). SleepMinder: an innovative contact-free device for the estimation of the apnoea-hypopnoea index, *Annual international conference of the IEEE engineering in medicine and biology society*, 7091-9094.
- Zhang X., Zou J., He K., Su J. (2015). Accelerating very deep convolutional networks for classification and detection, *IEEE transactions on pattern analysis and machine intelligence*, 38 (10): 1943-1955.