



**İSKENDERUN TEKNİK**  
ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**YÜKSEK  
LİSANS  
TEZİ**

**DERİN SİNİR AĞLARIYLA  
ELEKTROENSEFALOGRAFİ  
SİNYALLERİ SINIFLANDIRILARAK  
YENİDOĞANLARDA EPİLEPSİ  
TANI YÖNTEMİ GELİŞTİRİLMESİ**

**Süleyman RENCUZOĞULLARI**

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ  
ANABİLİM DALI**

**HAZİRAN 2021**





**İSKENDERUN TEKNİK ÜNİVERSİTESİ**



**DERİN SİNİR AĞLARIYLA ELEKTROENSEFALOGRAFİ SİNYALLERİ  
SINIFLANDIRILARAK YENİDOĞANLARDA EPİLEPSİ TANI YÖNTEMİ  
GELİŞTİRİLMESİ**

**Süleyman RENCUZOĞULLARI**

**YÜKSEK LİSANS TEZİ  
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**HAZİRAN 2021**

DERİN SİNİR AĞLARIYLA ELEKTROENSEFALOGRAFİ SİNYALLERİ  
SINIFLANDIRILARAK YENİDOĞANLARDA EPİLEPSİ TANI YÖNTEMİ  
GELİŞTİRİLMESİ

Yüksek Lisans Tezi

Süleyman RENCUZOĞULLARI

İSKENDERUN TEKNİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Haziran 2021

ÖZET

Bu tez, yenidoğanlarda nöbet tespit etme sorununu ele almaktadır. Bu tez çalışmasında Alexnet, resnet18, googlenet, densenet ve resnet50 dahil olmak üzere önceden eğitilmiş derin evrişim sinir ağlarını (p-DCNN) mantıklı bir şekilde yeniden yapılandıran bir transfer öğrenme tekniği çalışılmıştır. Bu ağlar, renkli görüntülere dönüştürülen çok kanallı elektroensefalografi (EEG) sinyallerinden yenidoğan nöbeti tespit etmek için kullanılmıştır. Bu sorunu çözmek için, transfer öğrenme tabanlı ağlar yerine doğrudan bir evrişim sinir ağı (CNN) gibi klasik derin bir sinir ağı yapısı (DNN) kullanılabilir. Ancak, bir DNN çok fazla eğitim verisine ihtiyaç duymasının yanında, çok fazla eğitim süresi ve yüksek performanslı hesaplama özelliğine sahip bir bilgisayar gerektirir. DNN'de ayrıca istenen sınıflandırma başarısını elde etmek için ayarlanması gereken kullanıcı tarafından belirlenmesi gerekli olan çok sayıda parametre vardır. Bu dezavantajları önlemek için, yenidoğan nöbet tespit problemini çözmek amacıyla bir transfer öğrenme tekniği önerilmiştir. Simülasyonların sonuçları ve istatistiksel analizler, nöbet tespiti için kullanılabilir bir transfer öğrenme tekniğinin etkinliğini göstermiştir.

Anahtar Kelimeler : Transfer öğrenimi, derin evrişimli sinir ağları, yenidoğan nöbetleri,  
derin öğrenme  
Sayfa Adedi : 56  
Danışman : Dr. Öğr. Üyesi Abdullah ÇALIŞKAN

DEVELOPMENT OF AN EPILEPSY DIAGNOSIS METHOD IN NEONATES BY  
CLASSIFYING ELECTROENCEPHALOGRAPHY SIGNALS WITH DEEP NEURAL  
NETWORKS (M. Sc. Thesis)

Süleyman RENCUZOĞULLARI

ISKENDERUN TECHNICAL UNIVERSITY  
INSTITUTE of GRADUATE STUDIES

June 2021

ABSTRACT

The paper considers the problem of detecting neonatal seizures via a transfer learning technique that judiciously reconstructs pretrained deep convolution neural networks (p-DCNN), including alexnet, resnet18, googlenet, densenet and resnet50 in this thesis. These networks are utilized to detect neonatal seizure from multi channel electroencephalography (EEG) signals converted to color images. To handle this problem, it may be directly used a deep neural network (DNN) such as a convolution neural network (CNN) instead of transfer learning based networks. However, a DNN requires too much training data, too much training time and a computer with high performance computational capability. The DNN also has a number of user supplied parameters that must be tuned to obtain desirable classification success. In order to prevent these drawbacks, we proposed a transfer learning technique to solve neonatal seizures detection problem. The results of simulations and the statistical analysis enable us to devise a transfer learning technique that can be employed for seizure detection.

Key Words : Transfer learning, deep convolutional neural networks, neonatal seizures, deep learning  
Page Number : 56  
Supervisor : Assist. Prof. Abdullah ÇALIŞKAN

## TEŞEKKÜR

Bu çalışmamda hiçbir desteği esirgemeyen, çok büyük katkıda bulunan danışman hocam Sayın Dr. Öğr. Üyesi Abdullah Çalışkan'a, yoğun çalışmalarım esnasında motivasyon kaynağım can eşim Yasenya'ya , bugüne kadar arkamda duran ve çalışmaya teşvik eden aileme, çalışmalarımda yardımcı olan kız kardeşlerim Delal ve Yaren'e, tez aşamasına gelene kadar ki süreçte destek olan arkadaşlarım Biyomedikal Mühendisi Özkan Kömür'e, Tıp Mühendisi Hasan Şerif Gülen'e, İnşaat Mühendisi Ali Beyaz'a, Mekatronik Mühendisi Ahmet Rencuzoğulları'na, Ali Bağdadi'ye, yoğun çalışma temposunda gösterdikleri hoşgörü ve desteklerinden dolayı 'Batı Tıbbi Cihazlar' şirket yetkilileri ve çalışma arkadaşlarım Şaban Kanatlı'ya, Sezer Taşkırın'a, Yemen Tuner'e ve Şakir Taze'ye sonsuz teşekkür ederim.

**İÇİNDEKİLER**

	<b>Sayfa</b>
ÖZET .....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER .....	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	xiv
SİMGELER VE KISALTMALAR.....	xv
1. GİRİŞ .....	1
2. YÖNTEM .....	7
2.1 Yöntemin Uygulanması .....	12
2.1.1 Veri Kümesi.....	12
2.1.2 Önışleme .....	12
3. SONUÇLAR ve TARTIŞMA .....	14
3.1 Deneysel Çalışma ve Sonuçlar .....	18
3.2 Optimizasyon Süreci.....	22
3.3 İstatistiksel Analiz .....	26
3.4 Farklı Sınıflandırıcılarla Genel Karşılaştırma .....	30
3.5 Karışıklık Matrisleri ve Zaman Karmaşıklığı Analizi.....	30
4. SONUÇLAR ve ÖNERİLER.....	37
KAYNAKLAR.....	38
EKLER .....	43
ÖZGEÇMİŞ.....	44

DİZİN ..... 45





**ÇİZELGELER**

<b>Çizelge</b>	<b>Sayfa</b>
Çizelge 2.1. Bu çalışmada kullanılan derin sinir ağlarının önemli özellikleri.....	7
Çizelge 3.1. Doğruluk değerlerinin açıklayıcı istatistiksel özellikleri.....	19
Çizelge 3.2. AUC değerlerinin tanımlayıcı istatistiksel özellikleri .....	21
Çizelge 3.3. Varyansların homojenlik testi.....	26
Çizelge 3.4. Ağlar için tek yönlü anavo testi .....	26
Çizelge 3.5. Olası her ağ çiftinin istatistiksel karşılaştırılması.....	28
Çizelge 3.6. Farklı sınıflandırıcılarla genel karşılaştırma.....	29
Çizelge 3.7. CNN için kullanılan parametre seti .....	33
Çizelge 3.8. Ağların eğitim süresi (saniye cinsinden) .....	36

## ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Yenidoğan nöbetin saptanması için Alexnet uygulaması.....	9
Şekil 2.2. Bipolar EEG montajı .....	10
Şekil 2.3. Bir EGG sinyal penceresinden veri seti görüntülerinin üretim süreci. ....	11
Şekil 3.1. EEG sinyallerinden elde edilen bazı görüntü örnekleri (1) .....	14
Şekil 3.2. EEG sinyallerinden elde edilen bazı görüntü örnekleri (2) .....	15
Şekil 3.3. EEG sinyallerinden elde edilen bazı görüntü örnekleri (3) .....	15
Şekil 3.4. EEG sinyallerinden elde edilen bazı görüntü örnekleri (4) .....	16
Şekil 3.5. Önerilen yöntemin yapısı.....	17
Şekil 3.6. Her denek için normal vaka ve nöbet sayısı .....	19
Şekil 3.7. Alexnet ve Resnet18 AUC ve Doğruluk (%) değerleri. ....	23
Şekil 3.8. Googlenet ve Densenet AUC ve Doğruluk (%) değerleri. ....	24
Şekil 3.9. Resnet50 ve CNN AUC ve Doğruluk (%) değerleri. ....	24
Şekil 3.10. Eğitim süreci boyunca test verilerindeki doğruluğun değişimi. ....	25
Şekil 3.11. Her ağ için çentikli kutu grafiği.....	27
Şekil 3.12. Her ağ için karşılaştırma matrislerinin ortalama değeri .....	31
Şekil 3.13. Alexnet, Resnet18, Resnet50, Googlenet, Densenet ile ilgili olarak karşılaştırma matrisleri.....	33
Şekil 3.14. Alexnet, Resnet18, Resnet50, Googlenet, Densenet ile ilgili olarak karşılaştırma matrisleri.....	34
Şekil 3.15. Alexnet, Resnet18, Resnet50, Googlenet, Densenet ile ilgili olarak karşılaştırma matrisleri.....	35

## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

<b>Kısaltmalar</b>	<b>Açıklamalar</b>
<b>AUC</b>	Area Under the Curve
<b>EEG</b>	Elektroensefalogram
<b>CNN</b>	Convolutional Neural Network
<b>DNN</b>	Deep Neural Network
<b>FCNN</b>	Fully Convolutional Neural Network
<b>Hz</b>	Hertz
<b>IIR</b>	Infinite Impulse Response
<b>MD</b>	Mean Difference
<b>p-DCNN</b>	Pretrained Deep Convolution Neural Network
<b>SVM</b>	Support Vector Machine
<b>SDA</b>	Stacked Denoising Autoencoders

## 1. GİRİŞ

Hipoksik-iskemik ensefalopati (beynin yeteri kadar oksijen alamaması), inme (felç) menenjit, enfarktüs dahil olmak üzere ciddi nörolojik disfonksiyonları olan pek çok hastalık yenidoğan nöbetlerine sebep olmaktadır [1].

EEG, normal veya anormal beyin elektriksel aktivite modellerininin görselleştirilmesinde kullanılır. Sadece nöbetlerle değil, bir dizi farklı koşulla bazı anormal paternler ortaya çıkabilir. Örneğin, kafa travması, felç, beyin tümörü veya nöbetlerden sonra belirli dalga türleri görülebilir. Bu türün yaygın bir örneği, beyin dalgalarının ritminin hastanın yaşı ve uyanıklık düzeyi için beklenenden daha yavaş olduğu "yavaşlama" olarak adlandırılır [2, 3].

Yenidoğan EEG kaydı, uyanıklık ve tüm uyku evrelerini yakalamak için en az 2 ila 3 saat sürmelidir. Yenidoğan EEG'si tipik olarak ekranda daha uzun bir zaman aralığıyla görüntülenir (15 mm/sn daha hızlı "kağıt hızı"), daha sıkıştırılmış görünen bir kayıt üretir. Bu sıkıştırılmış ekran, yenidoğan kayıtlarında değerlendirilmesi için çok önemli olan çok yavaş aktivitenin, asimetri ve asenkronların daha iyi görüntülenmesini sağlar. Bazı diğer modeller, nöbetlere doğru bir eğilimi gösterir. Bu dalgalar "epileptiform anormallikler" veya "epilepsi dalgaları" olarak adlandırılabilir. Sivri uçlar, keskin dalgalar ve diken-dalga deşarjları gibi görünebilirler. EEG'de kısmi nöbetler varsa, örneğin temporal lob gibi belirli bir bölgesinde EEG'de ani yükselmeler ve keskin dalgalar nöbetlerin nereden geldiğini gösterebilir. Genelleştirilmiş epilepsi, özellikle aynı anda her iki tarafta da başlıyorsa, beynin her iki tarafına geniş çapta yayılan diken-dalga deşarjları tarafından önerilmektedir [2-5].

Nöbet, bir grup nöronun hipersenkron deşarjının neden olduğu paroksizmal bir davranıştır. Yenidoğan nöbetleri, yenidoğanda nörolojik disfonksiyonun en yaygın açık belirtisidir [5].

Nöbetler genellikle önemli hastalıklarla ilişkilidir ve bazen özel tedavi gerektirir. Nöbetler, kardiyorespiratuar işlevi ve beslenmeyi etkileyebilir ve beyin gelişimi üzerinde uzun vadeli zararlı etkileri olabilir. Tekrarlayan neonatal nöbetlerle beyin hasarının potansiyel mekanizmaları şunları içerir. Hipoventilasyon/apne, hipoksiye neden olur (kardiyovasküler

kollapsa, serebral kan akışının azalmasına [CBF] ve hipoksik iskemik hasar riskinde artışa yol açar) veya hiperkarbi (CBF'de artışa ve artışa yol açar) intrakraniyal kanama riski (İSK). Yüksek kan basıncı, CBF ve İSK riskini artırır. Yüksek glikoliz, nöbetin neden olduğu beyin hasarını şiddetlendiren hipoglisemiye yol açar [2, 5]. Eksitator amino asitler (artan salınım), eksitotoksik beyin hasarına neden olabilir. Bu olumsuzluklar iyi yoğun bakım ve nöbetlerin kontrolü ile önlenabilir.

Yenidoğan nöbetleri daha büyük çocuklar ve yetişkinlerden farklıdır. En sık görülen neonatal nöbetler, klinik belirtiler sıklıkla gözden kaçırıldığı için süptil olarak tanımlanır [4,6]. Bunlar arasında tonik, gözlerin sarsılarak veya atılmaksızın yatay kayması, göz kapağı kırılma veya çarpınma, emme, şapırdatma veya diğer oral-bukkal-lingual hareketler, yüzme veya pedal çevirme hareketleri ve bazen apne nöbetleri yer alır [5]. Diğer neonatal nöbetler, uzuvların tonik uzantısı olarak, serebral veya dekortik duruşları taklit ederek ortaya çıkar. Bunlar özellikle prematüre bebeklerde görülür. Bir uzvun klonik hareketleri ile karakterize edilen, vücudun diğer bölgelerine veya diğer uzuvlara göç edebilen multifokal klonik nöbetler veya fokal klonik nöbetler, çok daha lokalize olanlar oluşabilir. İkincisinde, bebek genellikle bilinçsiz değildir.

Yenidoğan nöbetlerinin çeşitli nedenleri vardır. Bunlar şunları içerir [5]:

- Plasentanın bozulması (plasentanın uterustan erken ayrılması, zor veya uzun süreli doğum eylemi veya göbek kordonunun sıkışması nedeniyle doğumdan önce veya doğum sırasında oksijen eksikliği)
- Bakteriyel menenjit, viral ensefalit, toksoplazmoz, sifiliz veya kızamıkçık gibi doğumdan önce veya sonra edinilen enfeksiyon
- Doğumdan önce veya sonra inme
- Beyindeki kan pıhtısı
- Beyinde kanama
- Beyin doğum kusurları
- Kan şekeri veya elektrolit dengesizlikleri
- Akçaağaç şurubu idrar hastalığı, piridoksin bağımlılığı veya fenilketonüri (PKU) gibi metabolik bozukluklar

- Barbitürat, alkol, eroin, kokain veya metadon bağımlısı annelerden doğan bebekleri etkileyebilecek uyuşturucu yoksunluğu

Nadir durumlarda, yenidoğan nöbetlerine, beşinci gün nöbetleri veya beşinci gün nöbetleri olarak da bilinen iyi huylu ailesel yenidoğan nöbetleri adı verilen bir durum neden olur. Bu durum kalıtsaldır ve bebeğin annesi veya babası da bozukluğa sahip olacaktır. İyi huylu ailesel yenidoğan nöbetleri olan birçok bebek normal gelişir, ancak bazılarında erken çocukluk döneminde görülen gelişimsel gecikmeler olabilir [7].

Yenidoğan nöbetlerinin teşhisi zor olabilir çünkü nöbet kısa ve belirsiz olabilir. Ayrıca yenidoğan nöbetlerinin semptomları sağlıklı bebeklerde görülen normal hareket ve davranışları taklit edebilir. Semptomlar nöbet tipine bağlıdır - hafif, klonik, tonik veya miyoklonik. Hafif nöbetler, zamanında doğan bebeklerde daha yaygındır [8-10].

Hafif nöbetlerin belirtileri şunları içerir [2,5] :

- Rastgele veya gezinen göz hareketleri, göz kapağı yanıp sönmeye veya çarpınma, gözler yukarı yuvarlanma, göz açma, bakma
- Emme, şapırdatma, çiğneme ve dilin dışarı çıkması
- Bacakların olağandışı bisiklete binme veya pedal çevirme hareketleri
- Çarpınan veya mücadele eden hareketler
- Solunumda uzun duraklamalar (apne)

Klonik nöbetlerin belirtileri; yüz, dil, kol, bacak veya vücudun diğer bölgelerinin kaslarını içerebilen ritmik ani hareketler [10,3]

Tonik Nöbetlerin Belirtileri; kasların sertleşmesi veya sıkılaştırılması, başı veya gözleri bir tarafa çevirmek veya bir veya daha fazla kol veya bacağı bükme veya germek [10,3]

Miyoklonik nöbetlerin belirtileri; Bir kol veya bacak veya tüm vücudu içeren hızlı, tek sarsıntı hareketleri [10,3].

Yetişkinlerde ve daha büyük çocuklarda görülen nöbetlerle karşılaştırıldığında, yenidoğan nöbetlerini EEG (Elektroensefalogram) sinyallerinden faydalanmadan ayırt etmek çok

zordur [10,3]. Bu nedenle, yenidoğan nöbetlerini EEG sinyallerinden tespit etmek için oldukça uzmanlaşmış kişilere ihtiyaç vardır [10,3]. Bununla birlikte, bu sınıflandırma işlemi, EEG sinyallerinin karmaşık doğası nedeniyle son derece zaman alıcı ve yorucudur. Bu nedenle, uzman hekimlerin nöbetleri tespit etmesini desteklemek için bazı bilgisayar tabanlı ve makine öğrenimi teknikleri kullanılır [4].

Nöbetlerin tespiti, ön işleme, öznelik çıkarma ve sınıflandırma dahil olmak üzere üç ana adımı içerir. Nöbet tespitinin performansı, bu üç adımın uyumuna bağlıdır. Öncelikle ön işleme adımında gürültüyü azaltmak için EEG sinyalleri filtrelenir. Ardından, EEG sinyalleri bir pencere kullanılarak belirli sinyal parçalarına bölünür. İkinci adımda, sinyalin her bir parçasından bir dizi öznelik çıkarılır [11]. Son adımda, öznelikler ve etiketler arasındaki ilişkiler uygun bir sınıflandırıcı yardımıyla öğrenilir [2, 4]. Sınıflandırma performansı, yukarıda sayılan adımlara bağlı olmakla birlikte bu adımların çeşitli unsurlarına da ayrıca bağlıdır. Bu unsurlar gürültü filtresi, pencere uzunluğu, pencere kayma aralığı, özellik çıkarıcı tipi ve sınıflandırıcı [12] olarak sayılabilir. Bu nedenle, epileptik nöbetleri sınıflandırmak için farklı teknikler vardır.

En yaygın yöntemler, yenidoğanlarda nöbetleri yakalamak için eşik, sezgisel ve (if/then) kurallara dayalı yöntemlerdir. Önemli sayıda eşik yöntemi, ritmik deşarjları, çoklu yükselmeleri ve çok yavaş ritmik nöbetleri saptamak için belirli eşik değerlerini kullanır [13-16]. Otomatik yenidoğan nöbet tespiti, bir uzmanı taklit ederek EEG sinyallerinden nöbetleri tespit etmek için de önerilmektedir [17]. EEG sinyallerinin düşük ve yüksek frekans güç spektrumları, yeni doğandan kayıt edilen EEG sinyallerindeki nöbetleri saptamak için kullanılır [18]. Destek vektör makinesi (SVM) tabanlı sınıflandırıcı, zamansal bilgilerden yola çıkılarak sınıflandırma yapılması amacıyla kullanılır. Bu yöntem yenidoğan nöbetlerinde epileptik dalgaları saptamak için kullanılır [19], [20]. Yenidoğan nöbet tespiti atomik ayrıştırma tekniği kullanılarak da elde edilir [21]. Özellik çıkarma yöntemlerinin sınıflandırıcılar üzerindeki etkisi, yeni doğanın EEG sinyallerinde epileptik nöbetleri sınıflandırmak için en uygun olanı bulmak için değerlendirilir [22]. Gauss karışım modeline dayanan bazı istatistiksel yöntemler, epileptik nöbeti saptamak için kullanılır [23].

Yukarıda bahsedilen yöntemlerin performansı, kullanıcı tarafından sağlanan parametrelere, özellik çıkarma yöntemine, özellik / kanal seçimi / azaltma yöntemlerine, sınıflandırıcı

tipine göre bir çok dezavantaja sahiptir [4]. Ayrıca, birçok farklı uygulamada [24-31] görüleceği üzere DNN'nin artan başarısı, EEG sınıflandırma problemlerini çözmek için kullanılmıştır. Klasik yaklaşımların dezavantajlarını ortadan kaldırmak ve etkili bir sınıflandırma algoritması oluşturmak için bazı DNN tabanlı sınıflandırıcılar önerilmiştir.

CNN, piksel verilerini işlemek için özel olarak tasarlanmış görüntü tanıma ve işlemede kullanılan bir tür yapay sinir ağıdır. CNN'ler, genellikle görüntü ve video tanımanın yanı sıra öneri sistemleri ve doğal dil işlemeyi içeren makine vizyonunu kullanarak, tanımlayıcı görevleri gerçekleştirmek için derin öğrenmeyi kullanan güçlü görüntü işlemedir [6].

Bir sinir ağı, insan beynindeki nöronların çalışmasından sonra modellenen bir donanım ve/veya yazılım sistemidir. Geleneksel sinir ağları, görüntü işleme için ideal değildir ve görüntüleri düşük çözünürlüklü parçalar halinde beslemeleri gerekir. CNN'nin "nöronları", insanlarda ve diğer hayvanlarda görsel uyaranların işlenmesinden sorumlu alan olan ön lobunkilere benzer şekilde düzenlenmiştir. Nöron katmanları, geleneksel sinir ağlarının parçalanmış görüntü işleme probleminden kaçınarak tüm görsel alanı kaplayacak şekilde düzenlenmiştir.

Bir CNN, azaltılmış işleme gereksinimleri için tasarlanmış çok katmanlı bir sensöre çok benzer bir sistem kullanır. Bir CNN'nin katmanları, bir giriş katmanı, bir çıkış katmanı ve çoklu evrişim katmanları, havuz katmanları, tam bağlantılı katmanlar ve normalleştirme katmanlarını içeren bir gizli katmandan oluşur. Görüntü işleme için sınırlamaların kaldırılması ve artan verimlilik, görüntü işleme ve doğal dil işleme için sınırlı eğitim için çok daha etkili, daha basit bir sistemle sonuçlanır [32].

Yetişkinlerde epileptik nöbetleri tespit etmek için DNN'ye dayalı bir dizi yöntem vardır. [33]. Stokastik gürültü arındırma otomatik kodlayıcılar, çıkarılan özellikler mel-frekans spektral özellikleri kullanarak sivri ve / veya keskin dalgalar, genelleştirilmiş periyodik epileptik form deşarjları ve periyodik lateralize epileptik form deşarjları dahil olmak üzere üç önemli modeli sınıflandırmak için kullanılmıştır [34]. Epileptik nöbetleri sınıflandırmak için DNN'ye dayalı yığınlanmış otomatik kodlayıcı bir kanal seçim tekniği ile birlikte kullanılmıştır [35]. Ayrıca DNN tabanlı başka bir derin sinir ağı çeşidi 1 boyutlu derin CNN [36, 37]. Ullah I kullanılarak EEG sinyalleri sınıflandırılmıştır. Daha ileri çalışmalarda 1 boyutlu derin CNN, CNN ağının derinliğinin etkisini görmek için de



kullanılmıştır [38]. DNN ayrıca nöbet tespiti için yüksek çözünürlüklü çok kanallı EEG verileri ile de kullanılır [39]. Bu ağların yanı sıra, bir nöbeti temsil eden spektral, zamansal ve uzamsal modelleri tespit etmek için mevcut evrişim mimarisi [40] ve uzun kısa süreli bellek ağları [41-42] gibi bazı hibrit ağlar kullanılır. Öte yandan, yenidoğanda nöbetin varlığını saptamak için derin öğrenme tekniğini kullanan son derece sınırlı sayıda çalışma [38,44-46] vardır.

Epileptik nöbetin saptanması için önerilen tüm DNN'lerin, çok fazla veri gerektiren, karmaşıklık, optimizasyon yöntemi seçimi ve kullanıcı tarafından sağlanan parametre ayarları dahil olmak üzere çok sayıda dezavantajı vardır. Bu çalışmada bu sorunların üstesinden gelmek, yenidoğanlarda epileptik nöbeti sınıflandırmak için yeni bir teknik önerilmiştir. Nöbetleri tespit etmek için hem çok katmanlı derin sinir ağları hem de transfer öğrenmeye dayanan yöntem önerilmiştir. Önerilen modelin girişi, 3 kanallı 24 bit renkli görüntülere dönüştürülen ham EEG sinyalleri kullanılarak oluşturulmuştur. Epilepsi hastalığını tespit etmek için alexnet, googlenet, densenet, resnet dahil olmak üzere p-DCNN kullanılmıştır. Önceden eğitilmiş ağın son üç katmanı yenidoğan EEG sinyallerinden nöbetlerin tespiti için kullanılmıştır. Bu üç katman tamamen bağlı katman, bir softmax katmanı ve bir sınıflandırma katmanı dahil olmak üzere son üç katmanın eğitiminden sonra, çok derin evrişimli sinir ağı epileptik nöbeti sınıflandırmaya hazırdır. Bu amaçla, son derece zor ve zaman alıcı süreçler kullanmadan Image Net veri tabanından [26] yaklaşık 1,2 milyon görüntü üzerinde eğitilmiş p-DCNN' ler kullanılmıştır.

## 2. YÖNTEM

Geleneksel sinir ağıları bir giriş katmanından, bir veya daha fazla gizli katman ve çıktı katmanından oluşur. Bu ağlarda, bir katmandaki tüm nöronlar bir önceki katmanda bulunan her nörona bağlanır. Bu nedenle, bu tür ağlara tam bağlı ağ denir. Ancak, bu ağlar çok fazla bağlantı nedeniyle büyük boyutlu görüntülerin söz konusu olduğu sınıflandırma problemleriyle başa çıkmakta yetersiz kalır. Çünkü çok sayıda giriş, ayarlanması gereken çok sayıda ağırlığın ortaya çıkmasına neden olur [16]. Bu çok sayıda ağırlık ciddi bir hafıza ve ileri düzeyde optimizasyon yöntemleri gerektirir. Ancak, CNN ilgili bilgileri işlenmiş bir ham görüntüde koruyarak bu sorunu çözer. CNN'nin nöronları üç boyutta düzenlenmiştir: 3 kanallı renkli bir görüntü gibi genişlik, yükseklik ve derinliğe sahiptir. Bir katmandaki nöronlar, önceki katmanda bulunan sınırlı sayıda nörona bağlıdır.

Bir CNN üç ana katman içerir ; evrişim, havuzlama ve tamamen bağlantılı katmanlar.

Evrişim katmanı, giriş katmanındaki yerel bir bölgeye az sayıda bağlantısı olan her nöronun çıktısını üretmekten sorumludur. Giriş görüntüsündeki bu yerel bölge, bu çıkış nöronu tarafından temsil edilir [4].

Çizelge 2.1. Bu çalışmada kullanılan derin sinir ağlarının önemli özellikleri

<b>Evrişim Ağı</b>	<b>Parametre</b>	<b>Giriş Pikseli</b>	<b>Ağ Boyutu</b>	<b>Derinlik</b>
Alexnet	61 M	227 x 227 x 3	227 MB	8
Resnet18	11.7 M	224 x 224 x 3	44 MB	18
Googlenet	7 M	224 x 224 x 3	27 MB	22
Densenet	20 M	224 x 224 x 3	77 MB	201
Resnet50	25.6 M	224 x 224 x 3	96 MB	50
CNN	169 K	200 x 200 x 3	3 KB	6

Her bağlantı her bir giriş pikseliyle çarpılarak hesaplanır.

Havuzlama katmanı, CNN'nin karmaşıklığını azaltmak ve ağı derinliğini koruyarak aşırı öğrenmeyi önlemek için konvolüsyon katmanının çıktısına alt örnekleme işlemi

uygulanması amacıyla oluşturulur. Tamamen bağı katman, her sınıfı havuz katmanındaki nöronun çıktısına bağlar. Bu katman, geleneksel bir sinir ağına benzer [4].


Herhangi bir görüntü sınıflandırma probleminine uygulamak için kullanıcı tarafından sağlanan birkaç parametrenin CNN için düzenlenmesi gerekir. Bu nedenle, bir CNN'nin oluşturulması yorucu ve zaman alıcı bir süreçtir. Neyse ki, birkaç yapısal değişiklikle alexnet, resnet18, googlenet, densenet ve resnet50 dahil olmak üzere p-DCNN'nin ek eğitimiyle birkaç görüntü sınıflandırma problemini çözmek için iyi tasarlanmış bazı CNN'ler [47] vardır. Bu ağlar, ImageNet veritabanından yaklaşık 1,2 milyon görüntü ile farklı araştırma grupları tarafından eğitilmiştir. Parametre sayısı, giriş boyutu, ağ boyutu ve derinlik gibi bazı temel özellikler belirlenmelidir.

### *Alexnet*

Alexnet [48] , LeNet [49] adlı ilk önerilen evrişim sinir ağına benzer şekilde yapılandırılmıştır. LeNet ile karşılaştırıldığında, alexnet'in daha fazla katmanı, filtresi ve parametresi vardır. Alexnet (bkz. Şekil 1) 11x11, 5x5 ve 3x3 evrişim katmanına, havuz katmanına ve tamamen bağı ağına sahiptir. Alexnet, bilgisayar destekli iki Nvidia Geforce GTX 580 GPU ile stokastik gradyan alçalma optimizasyon tekniği ile eğitilmiştir. 2012 yılında bu mimari sayesinde ImageNet veritabanının hata oranı %26.2'den %15.4'e düşürülmüştür.

### *Resnet*

Artık Sinir Ağı (Resnet) [50] bağlantıları atlayan ve yoğun toplu normalleştirme özelliğine sahip yeni bir DNN olarak önerilmektedir. Bu tarz çok katmanlı ağlarda aşırı yükten dolayı bir bozulma sorunu ortaya çıkar.



Şekil 2.1. Yenidoğan nöbetin saptanması için Alexnet uygulaması

Bu sorun temelde, derin CNN'lerde yakınsama sürecini etkiler. Doğruluk belli bir noktadan sonra, artan katmanlar nedeniyle hızla azalır. Resnet [50] klasik fonksiyon ilişkilerini öğrenmek yerine katman girdilerine referansla artık fonksiyonları öğrenerek katmanları


yeniden formüle ederek derin bir CNN'lerde bozulma problemini çözmeye çalışır. Resnet18 ve Resnet50 dahil olmak üzere farklı Resnet türleri sırasıyla küçük ve büyük ölçekli problemler için kullanılır [4].

### *Googlenet*




Googlenet yapısındaki başlangıç modülleri nedeniyle karmaşık bir mimariye sahiptir [51]. Genel olarak, bu mimari ardışık bir yapıda evrşimi yığmaktan ve katmanları birleştiren CNN'lerden biridir. Ayrıca bu yeni model, bellek ve güç kullanımında önemli avantajlara sahiptir. Çünkü tüm katmanları istiflemek ve çok sayıda filtre eklemek, ağır bir hesaplama ve hafıza maliyeti getirir ve aşırı öğrenme olasılığını artırır. Bu durumun üstesinden gelmek için, googlenet'de paralel modüllerde kullanılmıştır [52]. Ayrıca 22 katmanlı googlenet,% 5.7 hata oranıyla ImageNet 2014 yarışmasının galibi olmuştur.

### *Densenet*

Densenet [53], hiçbir optimizasyon zorluğu göstermeden aynı özellik-harita boyutuna sahip herhangi iki katman arasında doğrudan bir bağlantı kurar. Densenet, artan katman ve parametre sayısına rağmen performans düşüşü veya aşırı öğrenmenin belirtilerini göstermeden başarılı sonuçlar üretir. Densenet'in birçok önemli avantajı vardır. Azalan gradyan problemini özellik yayılımı ile güçlendirerek çözer. Ayrıca belirli öznitelikleri kullanarak parametre sayısının azaltmasını sağlar [4].



Şekil 2.2. Bipolar EEG Montajı [4]



Şekil 2.3. Bir EEG sinyal penceresinden veri seti görüntülerinin üretim süreci [4]

## 2.1 Önerilen yöntemin uygulanması

Önceden eğitilmiş ağlar, daha önce görülmemiş görüntülerle bu ağlara uygun eğitim stratejisinin uygulanması şartıyla neredeyse tüm görüntü türlerini sınıflandırma yeteneğine sahiptir. Bu uygulamada, önceden eğitilmiş ağın son üç katmanı, yenidoğanlarda epileptik dalgaları sınıflandırmak için uyarlanmıştır. Tamamen bağlı katman, bir softmax katmanı ve bir sınıflandırma çıktı katmanı dahil olmak üzere son üç katmanın çıkarılmasından sonra, farklı sayıda nöron ve sınıf içeren yeni katmanlar önceden eğitilmiş ağlara uyarlanır [4].

### 2.1.1 Veri Kümesi

Veri seti Helsinki Üniversite Hastanesinde epilepsi olduğu bilinen 39 yenidoğandan kaydedilmiştir [3]. EEG sinyallerinin medyan kayıt süresi yaklaşık 74 dakikadır. EEG sinyallerinde gözlenen nöbet, üç uzman tarafından bağımsız olarak belirlenmiştir. Her uzman tarafından ortalama 460 nöbet tespit edilmiştir. EEG sinyalleri, 256 Hz örnekleme frekansına sahip bir NicOne EEG amplifikatörü ile kaydedilmiştir. Şekil 2'de gösterilen 19 elektrotlu EEG başlığı, bipolar EEG montajı dahil olmak üzere uluslararası standartlara göre yerleştirilmiştir [3, 4].

### 2.1.2 Ön işleme

EEG sinyallerinden epileptik nöbet tespiti, tipik geleneksel yaklaşımda ön işleme, özellik çıkarma ve sınıflandırma dahil olmak üzere üç ana adıma sahiptir. EEG sinyalleri, ön işleme adımında sinyal / gürültü oranını artırmak için filtrelendirir. Ayrıca sinyaller, ilk adımda bir pencereleme tekniği kullanılarak yönetilebilir parçalara bölünür. Bazı özellik çıkarma teknikleri kullanılarak, ikinci adımda bu parçalardan özellikler çıkarılır. Son adımda özellikler ve ilgili etiketler arasında bağlantı kurmak için uygun bir sınıflandırıcı tasarlanır [4].

Ancak bu tez çalışmasında nöbeti tespit etmek için farklı bir teknik uygulanmaktadır. Yeni doğanlarda ilk olarak, EEG sinyalleri 9. dereceden bant geçiren IIR ile filtrelendirir. Bu amaç için sinyale 0,3-30 Hz kesme frekanslı butterworth filtre uygulanmıştır. Şebeke gürültüsünün elemine edilmesi için 50 Hz notch filtre kullanılmıştır [4].


İkinci olarak, EEG sinyalleri veri setindeki 3 uzman görüşüne göre etiketlenmiştir. Eğer en az 2 uzman sinyal parçasının epileptik nöbet geçirdiğini kabul ederse, her örnek için bir aksi takdirde sıfır olarak etiketleme yapılmıştır. Bu işlemin ardından EEG sinyalleri her kanal için 30 saniye uzunluğunda ve 2 saniye kayan aralıklarla pencerelere bölünür. Çünkü nöbet en az 30 saniye aralıklarla tespit edilebilmektedir [4]. Kaydırma sırasında pencere en az % 50 nöbet süresi içeriyorsa, pencereyi nöbet vakası olarak etiketlendi, aksi takdirde normal durum olarak etiketlendi.

Önerilen yöntemin uygulanması sırasında karşılaşılan en önemli sorunlardan biri, önceden eğitilmiş bir ağ için girdi görüntülerinin üretilmesidir. Şekil 3'ün sol tarafında gösterilen bir EEG penceresindeki zaman serileri, kanallar ( $Y = 18$ ), zaman serileri ( $X = 7680$ ) ve EEG sinyallerinin genliği ( $Z = 18 \times 7680$ ) kullanılarak görselleştirilir. Bu işlemden sonra, ilişkileri  $Z = f(X; Y)$  fonksiyonu olarak düşünülebilen bir veri üçlüleri setine ( $X; Y; Z$ ) bir yüzey çizilir. Renklendirme tekniği, değerler, Şekil 3'ün ortasında gösterilen yüzey grafiklerini elde etmek için üst değerler (sarı), alt değerler (mavi) arasında değişir. Şekil 3'ün sağında gösterilen yüzey grafiğinin üstten görünümü, bir ağ eğitmek için kullanılır. Şekil 4'te daha fazla görüntü örneği gösterilmektedir. Tamamen bağlı bir katman, bir softmax katmanı ve bir sınıflandırma çıktı katmanı dahil olmak üzere son üç katman değiştirildikten sonra p-DCNN'ler bu görüntüler kullanılarak yeniden eğitilir. Alexnet için eğitim süreci Şekil 1'de görülebilir. Önerilen yöntemin genel yapısı da Şekil 5'te gösterilmektedir [4].




### 3. SONUÇLAR ve TARTIŞMA

Bu çalışmada, alexnet, resnet18, googlenet, densenet ve resnet50 dahil olmak üzere p-DCNN'lerin sınıflandırma performansını, yenidoğan nöbetleri tahmin etmek için kullanılan bir EEG veri setinde değerlendirilmiştir. Ayrıca, transfer öğrenme tekniği ile CNN arasındaki farkı ortaya çıkarmak için 6 derinlik boyutuna sahip geleneksel bir CNN oluşturulmuştur [4].




Şekil 3.1. EEG sinyallerinden elde edilen bazı görüntü örnekleri [4]




Şekil 3.2. EEG sinyallerinden elde edilen bazı görüntü örnekleri [4]



Şekil 3.3. EEG sinyallerinden elde edilen bazı görüntü örnekleri [4]



Şekil 3.4. EEG sinyallerinden elde edilen bazı görüntü örnekleri [4]



Şekil 3.5. Önerilen yöntemin yapısı

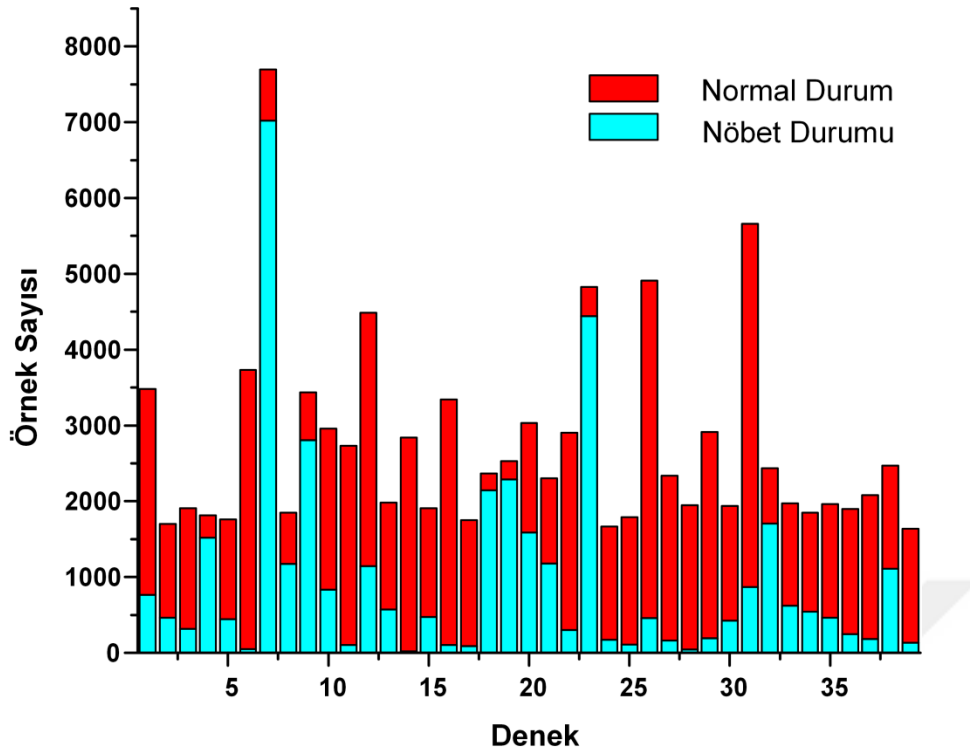


Tezin bu bölümde, genel deneysel düzenek açıklanmış, sonuçlar tartışılmış ağların optimizasyon sürecini araştırılmış, ayrıntılı istatistiksel analizler verilmiştir, bazı epileptik nöbet tespit algoritmalarıyla genel karşılaştırma yapılmıştır. Karşılaştırma matrisleri oluşturularak sonuçlar yorumlanmıştır. Son olarak zaman karmaşıklığı analiziyle yapılmıştır [4].

### **3.1. Deneysel Çalışma ve Sonuçlar**

Bu tez çalışmasında yeni doğanlarda nöbet tespit etmek için transfer öğrenme tekniğine dayalı bir yöntem geliştirilmiştir. P-DCNN girdi olarak ham EEG verilerini alır. Bu ham EEG sinyalleri 256 Hz (veya saniyede 256) örneklem alınarak oluşturulmuştur. EEG sinyallerinin her 7680 EEG örneğinin (veya her 30 saniyede) 512 örnek (veya 2 saniye) kayan aralıklarla görüntüye dönüştürülmüştür [4].

39 hastadan alınan EEG sinyallerinden oluşturulmuş 106.796 görüntüden oluşan bir eğitim veri kümesi kullanılarak 19 ham EEG girişlerinden nöbetleri teşhis etmek için beş önemli p-DCNN ve geleneksel bir CNN kıyaslanmıştır. Toplam görüntülerden 69.527 görüntü normal durum olarak belirlenirken 37.269 görüntünün geri kalanı nöbet durumu olarak belirtilmiştir [4]. Denek için normal vaka ve nöbet sayısı, dengesiz veri seti problemlerinin gözlemlenebildiği Şekil 6'da görülebilir.



Şekil 3.6. Her denek için normal vaka ve nöbet sayısı [4]

Çizelge 3.1.. Doğruluk değerlerinin açıklayıcı istatistiksel özellikleri

	Alexnet	Resnet18	Googlenet	Densenet	Resnet50	CNN
Ortalama Değer	95,96	97,45	94,42	97,93	97,17	91,38
Maksimum Değer	99,83	99,84	99,93	100,00	100,00	99,92
Medyan Değeri	97,19	97,95	96,26	98,52	97,39	93,15
Minimum Değer	85,10	90,60	82,91	90,12	90,05	71,73
Standart Sapma	3,79	2,16	4,93	2,00	2,41	7,32

Hesaplama karmaşıklığını azaltmak için 2162 \* 1211 çözünürlüklü RGB görüntüler CNN, alexnet ve diğer ağlar için sırasıyla 200 \* 200, 227 \* 227 ve 224 \* 224 piksel çözünürlüğe düşürülür. Görüntüler her bir denek için rastgele olarak eğitim seti (% 50) test setine (%)

50) ayrılır. Tüm deneylerde p-DCNN'ler, yenidoğanda nöbet sınıflamasını öğrenmek için eğitim görüntülerinin kullanıldığı bir ortamda değerlendirilir. Test görüntüleri daha sonra eğitilmiş p-DCNN'lere beslenir ve sınıf etiketleri bu p-DCNN'ler aracılığıyla tahmin edilir [4].

Ağlar, ağırlıkların rastgele başlatılmasıyla eğitilir. Stokastik gradyan inişini, momentum = 0,9; başlangıç öğrenme hızı = 0,0003; epoch numarası = 10; ve her ağ yapısı ve her konu için 20'lik örnek sayılarına ayrılarak boyutu dahil olmak üzere varsayılan parametrelerle bir momentum optimizasyon tekniği ile kullanılmıştır. Genel olarak, ağ mimarilerinin kullanıcı tarafından sağlanan parametreleri ve optimizasyon algoritması, manuel bir ayarlama yoluyla seçilir. Çünkü bu parametrelerin seçimi için sistemli bir yol yoktur [4].

Elde edilen sonuçlar, doğruluk ve eğri altındaki alan (AUC) dahil olmak üzere iki metrik üzerinden değerlendirilir. Her bir p-DCNN ve CNN için 39 denekten elde edilen doğruluk ve EAA değerlerinin ortalama, maksimum (maks), minimum (min), medyan ve standart sapması (std) Çizelge 2 ve 3'te özetlenmiştir. Densenet, her iki metriğe göre de diğer yöntemlere göre daha iyi sınıflandırma performansına sahiptir [4].

Çizelge 3.2. AUC değerlerinin tanımlayıcı istatistiksel özellikleri

	<b>Alexnet</b>	<b>Resnet18</b>	<b>Googlenet</b>	<b>Densenet</b>	<b>Resnet50</b>	<b>CNN</b>
Ortalama	0,9844	0,9898	0,9794	0,9917	0,9881	0,9090
Maksimum	1,0000	1,0000	1,0000	1,0000	1,0000	0,9998
Medyan	0,9915	0,9940	0,9867	0,9958	0,9923	0,9396
Minimum	0,9451	0,9494	0,9250	0,9527	0,9379	0,6932
Standart Sapma	0,0166	0,0127	0,0218	0,0110	0,0136	0,0844

Her iki metriğe göre karşılaştırıldığında diğer yöntemlere göre. Doğruluk ve AUC değerlerine göre densenet'in diğer ağlar arasında en küçük std'ye sahip olduğu unutulmamalıdır. Bu, densenet'in sonucunun diğer yöntemlere kıyasla daha sağlam ve tekrarlanabilir olduğu anlamına gelir [4].

Şekil 7, doğruluk ve AUC değerleri için ağ başına denek sayısı ile test örneklerinin sınıflandırma oranlarının varyanslarını da gösterir. Googlenet'in ve özellikle CNN'in deneklere göre diğerlerine göre daha fazla düşüşlere sahip olduğu görülüyor. Öte yandan, densenet ve resnet18, diğerleri arasında hem AUC hem de doğruluk değerleri açısından düzleştirilmiş davranış sergiler. Bu aşamadan elde edilen gözlem Çizelge 2 ve 3'teki standart sapma değerleriyle örtüşmektedir [4].

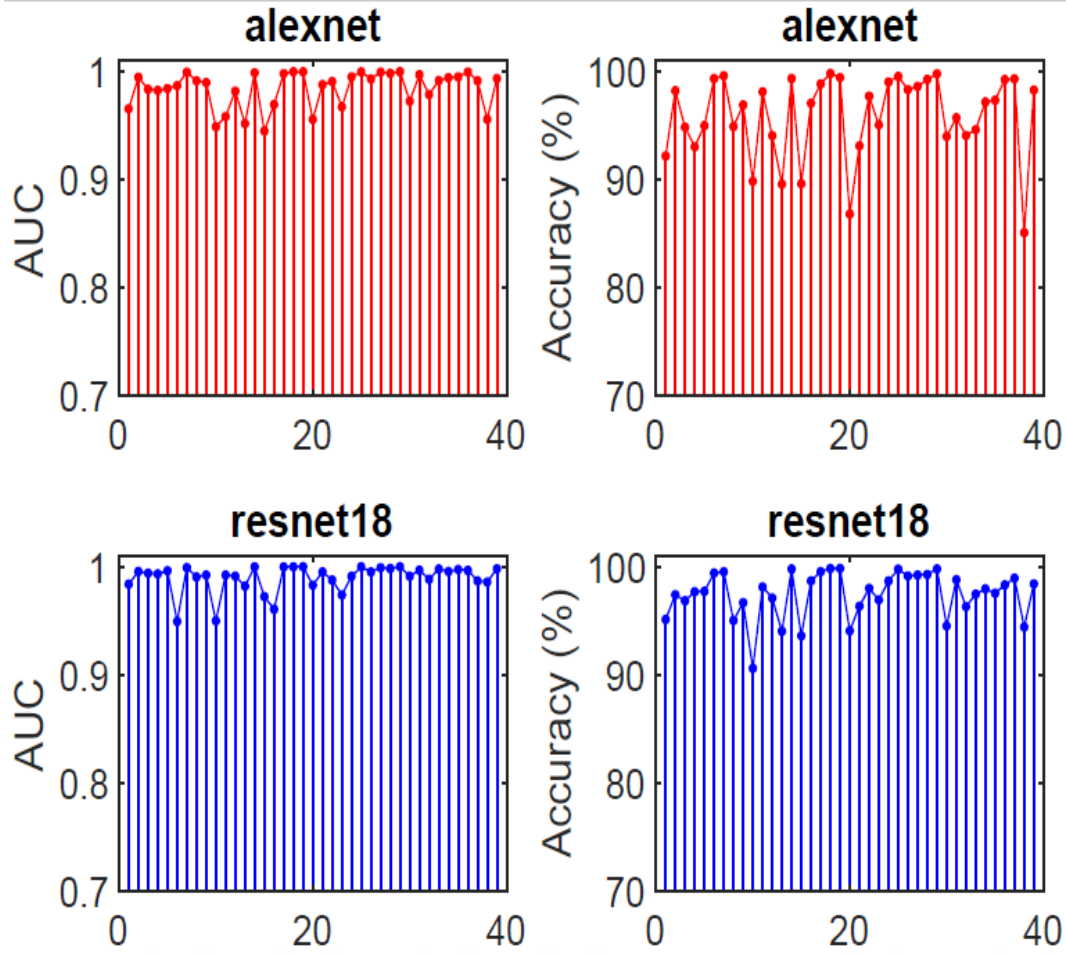
Transfer öğrenme tekniklerinin en büyük avantajlarından biri, çok katmanlı sinir ağlarında kolaylıkla gözlemlenebilen aşırı öğrenme problemlerini ele alarak veri setini sınıflandırmaktır. Örneğin, 61 milyon parametreye sahip alexnet'in 39 hastadan alınan



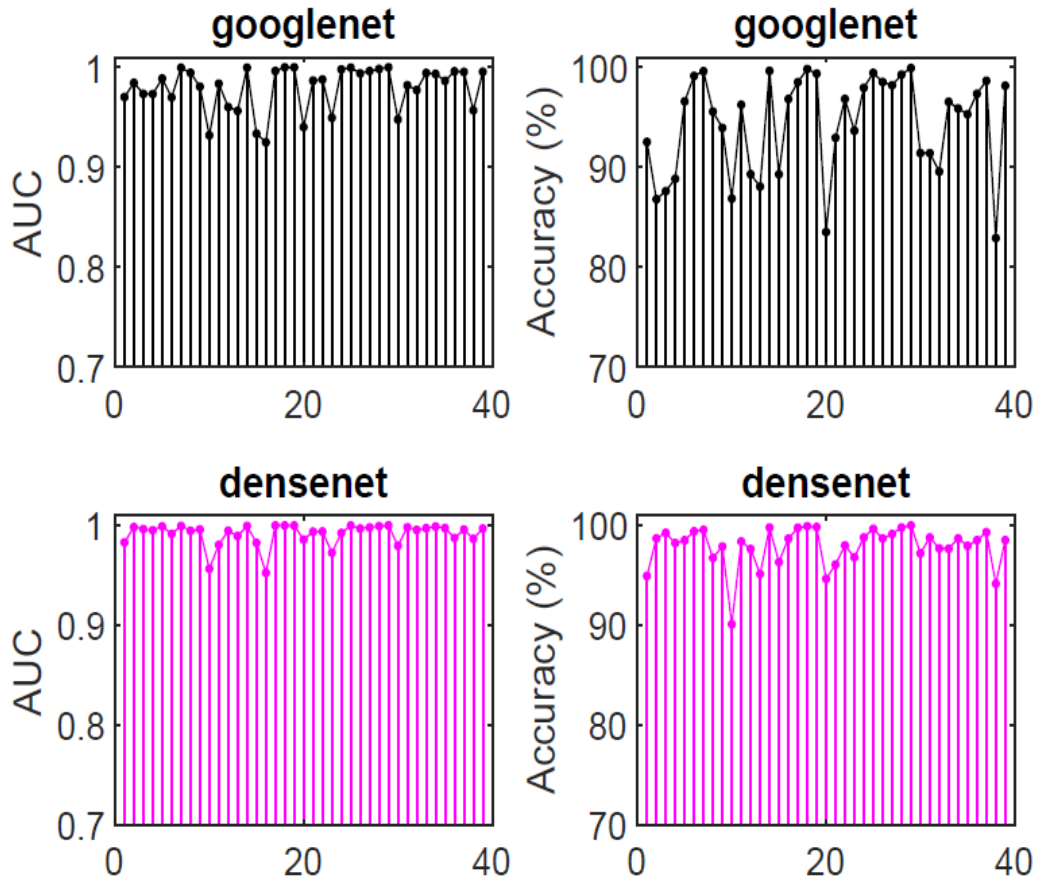
EEG sinyallerinden oluşturulmuş sadece 106.796 görüntü eğitildiğini düşündüğümüzde, eğitim verisi ile parametre numarası arasındaki dengesizlik ağı aşırı öğrenmesine yol açmaktadır. Bu durum tüm büyük ağlar için geçerlidir. Ancak bu çalışmada, sınırlı sayıda eğitim veri seti kullanarak yenidoğan nöbetini tespit etmek için transfer öğrenme tekniği kullanılarak bu durum çözülmektedir.

### **3.2. Optimizasyon Süreci**

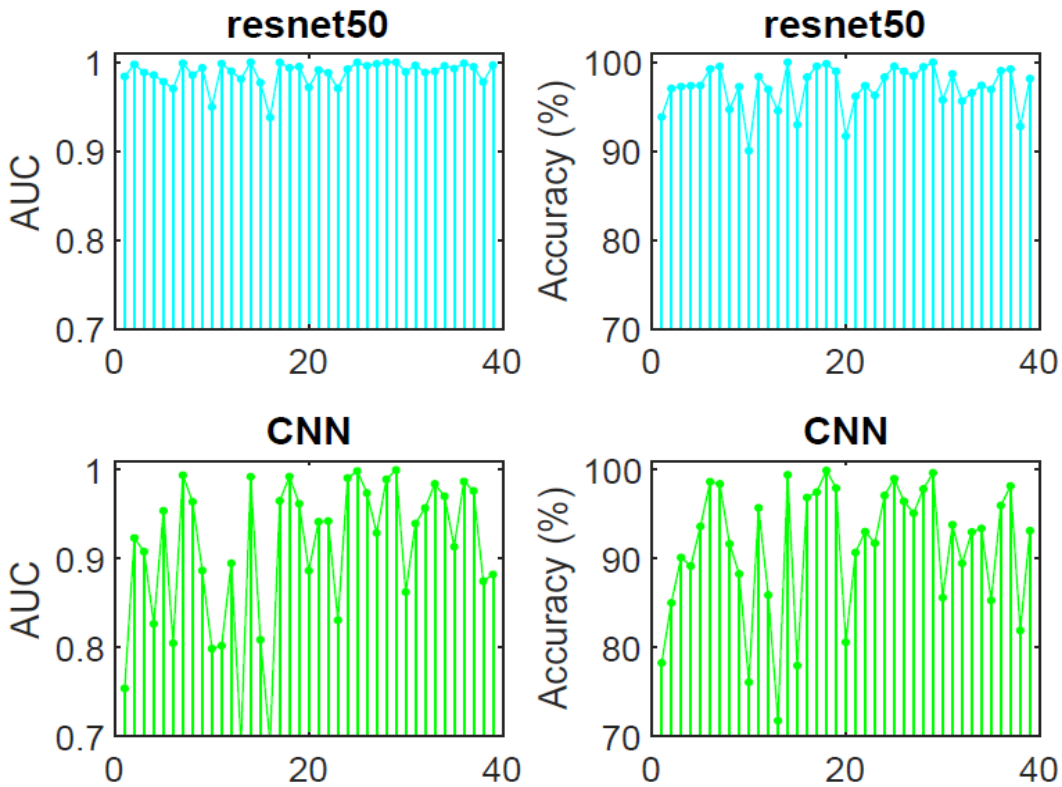
Bu tez çalışmasında, p-DCNN'ler ve CNN ağlarda kullanılan optimizasyon sürecini de gözlemlenmiştir. Ağlar, eğitim sırasında girdi örnekleri ve etiketler arasında azalma sağlamak için yinelemeli bir strateji izler. Şekil 8'de verilen sonuçlar denek 38 ve 39'dan elde edilir, burada test verilerindeki iterasyon boyunca doğruluğun değişimini göstermektedir. Sonuçlar, yinelemeler boyunca tüm ağların iç parametresinin aşamalı olarak güncellenmesinin genellikle sınıflandırma performansını iyileştirdiğini göstermektedir. Resnet18, resnet50 ve densenet doğruluklarının genellikle iterasyon sayısı ile monoton olarak arttığı gözlemlenmiştir. En iyi performansları, bozulma probleminin aşılması sayesinde Şekil 8'deki 38 ve 39 da iterasyon maksimum sayıya ulaştığında elde edilir. Ancak, alexnet ve özellikle googlenet ve CNN'de EEG sinyallerinden nöbet sınıflandırmasında dezavantaj yaratan bazı dalgalanmalar görülebilmektedir [4].




Şekil 3.7. Alexnet ve Resnet18 AUC ve Doğruluk (%) değerleri [4]



Şekil 3.8. Googlenet ve Densenet AUC ve Doğruluk (%) değerleri.



Şekil 3.9. Resnet ve CNN AUC ve Doğruluk (%) değerleri [4]



Şekil 3.10. Eğitim süreci boyunca test verilerindeki doğruluğun değişimi [4]

Çizelge 3.3. Varyansların homojenlik testi

	<b>Levene İstatistiği</b>	<b>df1</b>	<b>df2</b>	<b>p-value</b>
<b>Ortalamaya göre homojenlik testi</b>	20,097	5	228	0
<b>Medyana göre homojenlik testi</b>	12,742	5	228	0
<b>Medyana göre ve df ile ayarlanmış homojenlik testi</b>	12,742	5	121	0
<b>Kırılmış Ortalamaya göre homojenlik testi</b>	18,083	5	228	0

Çizelge 3.4. Ağlar için tek yönlü Anavo testi


	<b>Sum of Squars</b>	<b>df</b>	<b>Mean Square</b>	<b>F</b>	<b>p-value</b>
<b>Yöntemler arası Anavo Testi</b>	1193,05	5	238,611	13,42	0
<b>Yöntemler İçinde Anavo Testi</b>	4054,31	228	17,782	-	-
<b>Toplam</b>	5247	233	-	-	-

### 3.3. İstatistiksel Analiz

Son olarak doğruluk değerleri açısından p-DCNN'lerin ve CNN'nin genel bir istatistiksel karşılaştırması verilmiştir. Ağlar üzerinden nöbet tespiti, 39 denek üzerinden incelenmiştir. Bu nedenle, istatistiksel karşılaştırma 39 farklı sonuçla mümkündür. Verilere ilk olarak Levene testi uygulanmıştır. Grupların varyanslarının yaklaşık olarak eşit mi yoksa homojen mi olduğunu test eden varyans eşitliği için. Çizelge 4, p değerinin 0,05'ten küçük olduğunu göstermektedir. Bu, varyansların istatistiksel olarak önemli ölçüde farklı olduğu anlamına gelir. İkinci olarak, her ağ için istatistiksel önemi ayırt etmek için deneysel

verilere tek yönlü anova testi uygulanır. Elde edilen sonuçlar Çizelge 5'te gösterilmektedir. Küçük p değeri (0,00), ağların ortalamalar açısından aynı olmadığını gösterir [4].

Sonuçlar ayrıca Şekil 9'da gösterilen bir kutu çizimi tekniği kullanılarak görselleştirilir. Her bir kutuda, merkezi kırmızı çizgi medyanyı gösterir ve kutunun alt ve üst kenarları sırasıyla 25. ve 75. yüzdilik dilimleri gösterir. Çizgiler minimum ve maksimum veri noktalarına kadar uzanır. Bununla birlikte, bıyıklar, kırmızı renkli artı simgesi kullanılarak ayrı ayrı çizilen aykırı değerleri değerlendirmez [4].



Şekil 3.11. Her ağ için çentikli kutu grafiği [4]

Çizelge 3.5. Olası her ağ çiftinin istatistiksel karşılaştırması

Eşleştirilen Yöntemler	Ortalama Fark	p-Değeri	İşaret
Alexnet-Resnet18	-4,2145	0,6226	-
Alexnet-Googlenet	-1,1817	0,5904	-
Alexnet-Densenet	-4,6933	0,3058	-.
Alexnet-Resnet50	-3,9406	0,7978	-
Alexnet-CNN	1,8567	0,0000	Alexnet
Resnet18-Googlenet	0,3115	0,0187	Resnet18
Resnet18-Densenet	-3,2001	0,9961	-
Resnet18-Resnet50	-2,4474	0,9997	-
Resnet18-CNN	3,3499	0,0000	Resnet18
Googlenet-Densenet	-6,2329	0,0032	Densenet
Googlenet-Resnet50	-5,4802	0,0447	Resnet50
Googlenet-CNN	0,3171	0,0183	CNN
Densenet-Resnet50	-1,9686	0,9696	-
Densenet-CNN	3,8287	0,0000	Densenet
Resnet50-CNN	3,0760	0,0000	Resnet50
Ortalama fark ; 0,05			

Öte yandan, her bir olası ağ çiftinin istatistiksel karşılaştırması Çizelge 6'da verilmiştir. CNN ile her p-DCNN arasındaki istatistiksel önemi her bir p-DCNN lehine gözlemlenmiştir. Aynı zamanda Çizelge 6'da, googlenet ile diğer p-DCNN'ler arasında her bir p-DCNN lehine istatistiksel bir anlam olduğu görülmektedir. Ancak, alexnet, resnet18, resnet50 ve lehte herhangi bir istatistiksel anlamlılık bulunamamıştır.

densenet ( $p > 0,05$ ). Densenet, deneysel sonuçlardan elde edilen doğruluk ve AUC değerleri açısından bu çalışmada araştırılan diğer ağlardan daha iyi olsa da, alexnet, resnet18, resnet50 ve densenet dahil olmak üzere dört ağ açısından istatistiksel olarak bir farklılık yoktur [4].

Çizelge 3.6. Farklı sınıflandırıcılarla genel karşılaştırma

	Veri Kümesi	AUC	Veri kümesi bölme tekniği	ÖS*
SDA [36]	Helsinki	0,9570	Bir denekle kıyaslama	39
SDA_DB[36]	Helsinki	0,6600	Bir denekle kıyaslama	39
SDA_mDB[36]	Helsinki	0,8860	Bir denekle kıyaslama	39
SDA_T[36]	Helsinki	0,9230	Bir denekle kıyaslama	39
SVM [29]	Cork	0,9659	Bir denekle kıyaslama	18
CNN-6 [29]	Cork	0,9703	Bir denekle kıyaslama	18
CNN-11 [29]	Cork	0,9761	Bir denekle kıyaslama	18
D-CNN [3]	Rotterdam	0,7875	Eğitim (%75) ve Doğrulama (%25)	22
SVM [28]	Cork	0,9650	Bir denekle kıyaslama	18
FCNN [28]	Cork	0,9710	Bir denekle kıyaslama	18
SVM [30]	Cork	0,966	Bir denekle kıyaslama	18
1D-FCN[30]	Cork	0,981	Bir denekle kıyaslama	18
2D-FCN [30]	Cork	0,985	Bir denekle kıyaslama	18
SVM[30]	Helsinki	0,955	Bir denekle kıyaslama	39
2D-FCN[30]	Helsinki	0,956	Bir denekle kıyaslama	39
Alexnet	Helsinki	0,9844	Eğitim (%50) ve Test(%50)	39
Resnet18	Helsinki	0,9898	Eğitim (%50) ve Test(%50)	39
Googlenet	Helsinki	0,9794	Eğitim (%50) ve Test(%50)	39
<b>Densenet</b>	<b>Helsinki</b>	<b>0,9917</b>	<b>Eğitim (%50) ve Test(%50)</b>	<b>39</b>
Resnet50	Helsinki	0,9881	Eğitim (%50) ve Test(%50)	39
CNN	Helsinki	0,9090	Eğitim (%50) ve Test(%50)	39
ÖS* : Çalışmada kullanılan örnek sayısı				




### 3.4. Farklı sınıflandırıcılarla genel karşılaştırma

Bebeklerde EEG sinyallerinden nöbet tespiti için önerilen transfer öğrenme yöntemleri, Çizelge 7'nin en soldaki sütununda listelenen diğer bazı nöbet tespit algoritmalarıyla karşılaştırılmıştır. Her yöntemin ortalama AUC değeri Çizelge 7'de verilmiştir. Sonuçlar, DNN'nin CNN-6, CNN-11, D-CNN, FCNN, 1D-FCN ve 2D-FCN dahil olmak üzere DNN tabanlı temel yöntemler, geleneksel makine öğrenimine kıyasla genel olarak üstün sınıflandırma performansına sahiptir.

Çizelge 7'deki sonuçlara göre, sınıflandırma performansı densenet, alexnet, resnet18, resnet50 ve googlenet dahil önerilen p-DCNN'ler genellikle diğer yöntemlerden daha iyi olduğu görülmektedir. Resnet18, densenet ve resnet50 dahil olmak üzere transfer öğrenmeye dayalı ağların en büyük AUC değerlerini verdiği unutulmamalıdır. Alexnet ve googlenet, diğer yöntemlere kıyasla yeterli sonuçlar da üretir [4].

### 3.5. Karşılaştırma Matrisleri ve Zaman Karmaşıklığı Analizi

Epileptik nöbet tespiti sırasında karşılaşılan en önemli problemlerden biri, doğruluk değerinin yanlış bilgi sağlayabileceği dengesiz veri problemleridir. Dengesiz veri probleminin nasıl çözüldüğünü göstermek için her bir p-DCNN için Şekil 3.4'te görülen karşılaştırma matrisleri ile sağlanır. Ayrıca, ortalama tahmin yüzdesi Şekil 10'dan görülebilir [4].



Şekil 3.12. Her ağ için karşılaştırma matrislerinin ortalama değeri [4].


Resnet18 genellikle alexnet, googlenet, resnet50 ve CNN'den daha iyi performans gösterir. Densenet, dengesiz veri setine sahip deneklere rağmen çok verimli performans sağlar. Bu çalışmada kullanılan veri bölme tekniği, dengesiz veri sorununun ortaya çıktığı bazı uç durumlarda önerilen yöntemlerin performansını gözlemlememizi sağlar. Önerilen sınıflandırma performansı, dengesiz veri örnekleri ve sınırlı sayıda eğitim örneği olması durumunda bile çok etkilidir. Bebekleri dışarıda bırakma yaklaşımı ile karşılaştırıldığında, bu bölme tekniğinde sınırlı sayıda eğitim örneğimiz vardır. Ancak elde edilen tüm deneysel sonuçlar ve istatistiksel analizler bu zorluğun verimli bir şekilde ele alındığını göstermektedir. Şekil 3.4 'ten her denek için ayrı ayrı P-DCNN'lerin etkisi açıkça görülebilir [4].

Son olarak, gözlemlenen çalışma süreleri her ağ için saniye cinsinden rapor edilir. Simülasyonlar Intel i7 4 GHz işlemci, 16 GB RAM ve Nvidia Geforce GTX 980 Ti GPU içeren bir bilgisayarda gerçekleştirildi. Çizelge 8'de listelenen çalışma süreleri tüm ağların 38. ve 39. denekleri için elde edildi. Gözlemlenen çalışma süreleri, ağların karmaşıklığı ile tutarlı görünmektedir. Densenet'te daha yüksek çalışma süresinin nedeni, derinliğinin


yüksek yüksek olmasıdır. Ağın derinliği azaldığında, hesaplama süresi azalır. Densenet'in çalışma süresi diğer yonteme göre daha yüksek olsa da sonuçlar makul bir sürede alınır. Ayrıca, yüksek doğruluk ve düşük zaman karmaşıklığı sağlayan resnet18'i önerebiliriz [4].

Çizelge 3.7. CNN için kullanılan parametre seti

Katman Adı	Boyut	Filtre Sayısı	Uzaysal Kapsam	Ölçüler
INPUT CONV	200 x 200 x 3 200 x 200 x 96	0 96	0 7	0 $7 \times 7 \times 96 = 4\ 704$
RELU POOL CONV	200 x 200 x 96 200 x 200 x 96 100 x 100 x 128	0 0 128	0 2 5	0 0 $5 \times 5 \times 128 = 3\ 200$
RELU POOL CONV	100 x 100 x 128 100 x 100 x 128 50 x 50 x 96	0 0 96	0 2 5	0 0 $5 \times 5 \times 96 = 2\ 400$
RELU POOL CONV	50 x 50 x 96 50 x 50 x 96 25 x 25 x 48	0 0 48	0 2 3	0 0 $3 \times 3 \times 48 = 432$
RELU POOL	25 x 25 x 48 25 x 25 x 48	0 0	0 0	0 0
FC	1 x 2	0	0	$25 \times 25 \times 48 \times 2 = 60\ 000$
Toplam parametre sayısı = 70 736				



Şekil 3.13. alexnet, resnet18, resnet50, googlenet, densenet ile ilgili olarak her konu için karşılaştırma matrisleri [4]



Şekil 3.14. alexnet, resnet18, resnet50, googlenet, densenet ile ilgili olarak her konu için karşılaştırma matrisleri [4]

	alexnet	resnet18	googlenet	densenet	resnet50
27	0 1087 1 16 65 0 1	0 1085 1 7 74 0 1	0 1086 1 20 61 0 1	0 1085 1 8 73 0 1	0 1070 1 1 80 0 1
28	0 945 1 2 20 0 1	0 948 1 5 17 0 1	0 946 1 3 19 0 1	0 949 1 1 21 0 1	0 945 1 5 22 0 1
29	0 1360 1 3 92 0 1	0 1360 1 3 92 0 1	0 1360 1 1 94 0 1	0 1360 1 96 0 1	0 1360 1 96 0 1
30	0 738 1 41 171 0 1	0 743 1 41 171 0 1	0 749 1 77 135 0 1	0 743 1 15 197 0 1	0 743 1 29 183 0 1
31	0 2280 1 5 429 0 1	0 2386 1 24 410 0 1	0 2386 1 243 191 0 1	0 2391 1 29 405 0 1	0 2381 1 22 412 0 1
32	0 340 1 46 806 0 1	0 342 1 21 831 0 1	0 348 1 109 743 0 1	0 362 1 14 838 0 1	0 326 1 13 839 0 1
33	0 665 1 41 268 0 1	0 669 1 7 302 0 1	0 666 1 13 296 0 1	0 663 1 9 300 0 1	0 668 1 25 284 0 1
34	0 630 1 3 269 0 1	0 641 1 7 265 0 1	0 642 1 27 245 0 1	0 647 1 6 266 0 1	0 638 1 9 263 0 1
35	0 744 1 19 211 0 1	0 735 1 8 222 0 1	0 739 1 34 196 0 1	0 740 1 9 221 0 1	0 737 1 16 214 0 1
36	0 825 1 7 116 0 1	0 823 1 14 109 0 1	0 806 1 6 117 0 1	0 818 1 7 116 0 1	0 824 1 8 115 0 1
37	0 948 1 5 86 0 1	0 946 1 7 84 0 1	0 949 1 13 78 0 1	0 946 1 3 88 0 1	0 949 1 7 84 0 1
38	0 674 1 176 377 0 1	0 688 1 55 498 0 1	0 677 1 206 347 0 1	0 642 1 32 521 0 1	0 625 1 32 521 0 1
39	0 745 1 8 58 0 1	0 745 1 7 59 0 1	0 750 1 14 52 0 1	0 749 1 10 56 0 1	0 745 1 9 57 0 1

Şekil 3.15. Alexnet, resnet18, resnet50, googlenet, densenet ile ilgili olarak her konu için karşılaştırma matrisleri [4]

Çizelge 3.8. Ağların eğitim süresi (saniye cinsinden)

	<b>Alexnet</b>	<b>Resnet18</b>	<b>Googlenet</b>	<b>Densenet</b>	<b>Resnet50</b>	<b>CNN</b>
38. Denek	411	460	493	3483	752	459
39. Denek	269	298	327	2292	491	303



#### 4. SONUÇ ve ÖNERİLER

Epileptik nöbet veri setiyle ilgili deneyler, densenet ve resnet18'in, diğer p-DCNN'lere ve yüksek sayıda derinlik ve zaman gerektirirken geleneksel CNN'ye kıyasla daha iyi sınıflandırma performansı sağladığını göstermiştir. Önceden eğitilmiş DCNN'lere dahil edilen transfer öğrenimi sayesinde, epileptik nöbet, eğitim veri setlerinin sınırlı olduğu durumda bile epilepsi nöbetlerinin tespit edilebilmesini sağlar [4]. Ağın derinliği, optimizasyon stratejisi ve kullanıcı tarafından sağlanan bir dizi parametre gibi ayarlamalardan kaçınarak nöbet tespiti için CNN'leri kullanmak bir ayrıcalık oluşturacaktır. Ayrıca transfer öğrenimi bize, yeni doğarlarda epileptik nöbeti tespit etmek için makul eğitim ve test süreleri sağlar. Öte yandan önerilen yöntemde bir sınırlama vardır. Bu sınırlama tekniğin en az 10 zaman serisi gerektirmesidir. Çünkü EEG kanallarının nöbet tespit probleminde kullanılmak üzere renkli bir görüntüye dönüştürülmesi gerekir.



## KAYNAKLAR

1. Mizrahi, E.M., Kellaway, P. (1987). Characterization and classification of neonatal seizures. *Neurology* 37(12), 1837-1837.
2. Tapani, K.T., Vanhatalo, S., Stevenson, N.J. (2019). Time-varying eeg correlations improve automated neonatal seizure detection. *International Journal of Neural Systems* 29(04), 1850030.
3. Stevenson, N., Tapani, K., Lauronen, L., Vanhatalo, S. (2019) A dataset of neonatal eeg recordings with seizure annotations. *Scientific data* 6, 190039
4. Caliskan, A., Rencuzogullari, S. (2021). Transfer learning to detect neonatal seizure from electroencephalography signals. *Neural Computing and Applications*.
5. Britton JW, Frey LC, Hopp JLet. (2016); St. Louis EK, Frey LC, editors. *Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants* [Internet]. Chicago: American Epilepsy Society; Available from <https://www.ncbi.nlm.nih.gov/books/NBK390354/>
6. Zeiler, M.D., Fergus, R. (2013). Stochastic pooling for regularization of deep convolutional neural networks. arXiv preprint arXiv:1301.3557
7. Aicardi J. Neonatal seizures.(1991). Dam M, Gram L, editors. *Comprehensive epileptology*. New York. Raven Press.
8. Rose AL, Lombroso CT. (1970). A study of clinical, pathological, and electroencephalographic features in 137 full-term babies with a long-term follow-up. *Pediatrics* 1970;45(3):404-25
9. Fenichel GM, Olson BJ, Fitzpatrick JE (1980). Heart rate changes inconvulsive and nonconvulsive neonatal apnea. *Ann Neurol* 1980;7(6):577-82. CrossRef
10. Aicardi J, Arzimanoglu A, Guerrini R. (2004) *Aicardi's epilepsy in children*. 3rd ed. Philadelphia: Lippincott Williams & Wilkins.
11. Roux, N. L., & Bengio, Y. (2008). Representational Power of Restricted Boltzmann Machines and Deep Belief Networks. *Neural Computation*, 20(6), 1631-1649. doi:10.1162/neco.2008.04-07-510
12. Cheah, K.H., Nisar, H., Yap, V.V., Lee, C.Y. Convolutional neural networks for classification of music-listening eeg: comparing 1d convolutional kernels with 2d kernels and cerebral laterality of musical inuence. *Neural Computing and Applications* pp. 1-25.

13. Liu, A., Hahn, J., Heldt, G., Coen, R. (1992). Detection of neonatal seizures through computerized eeg analysis. *Electroencephalography and clinical neurophysiology* 82(1), 30-37.
14. Gotman, J., Flanagan, D., Zhang, J., Rosenblatt, B. (1997). Automatic seizure detection in the newborn methods and initial evaluation. *Electroencephalography and clinical neurophysiology* 103(3), 356-362 .
15. Celka, P., Colditz, P. (2002). A computer-aided detection of eeg seizures in infants: a singularspectrum approach and performance comparison. *IEEE transactions on biomedical engineering* 49(5), 455-462 .
16. Navakatikyan, M.A., Colditz, P.B., Burke, C.J., Inder, T.E., Richmond, J., Williams, C.E. (2006). Seizure detection algorithm for neonates based on wave-sequence analysis. *Clinical Neurophysiology* 117(6), 1190-1203.
17. Deburchgraeve, W., Cherian, P., De Vos, M., Swarte, R., Blok, J., Visser, G.H., Govaert, P., Van Huffel, S. (2008). Automated neonatal seizure detection mimicking a human observer reading eeg. *Clinical Neurophysiology* 119(11), 2447-2454 .
18. Hassanpour, H., Mesbah, M., Boashash, B. (2004). Time-frequency based newborn eeg seizure detection using low and high frequency signatures. *Physiological Measurement* 25(4), 935.
19. Ahmed, R., Temko, A., Marnane, W.P., Boylan, G., Lightbody, G. (2017). Exploring temporal information in neonatal seizures using a dynamic time warping based svm kernel. *Computers in biology and medicine* 82, 100-110.
20. Temko, A., Thomas, E., Marnane, W., Lightbody, G., Boylan, G. (2011). Eeg-based neonatal seizure detection with support vector machines. *Clinical Neurophysiology* 122(3), 464- 473 .
21. Nagaraj, S.B., Stevenson, N.J., Marnane, W.P., Boylan, G.B., Lightbody, G. (2014). Neonatal seizure detection using atomic decomposition with a novel dictionary. *IEEE Transactions on Biomedical Engineering* 61(11), 2724-2732.
22. Greene, B., Faul, S., Marnane, W., Lightbody, G., Korotchikova, I., Boylan, G. (2008). A comparison of quantitative eeg features for neonatal seizure detection. *Clinical Neurophysiology* 119(6), 1248-1261.
23. Thomas, E., Temko, A., Lightbody, G., Marnane, W., Boylan, G. (2010). Gaussian mixture models for classification of yenidoğan seizures using eeg. *Physiological measurement* 31(7), 1047.
24. Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks* 61, 85 – 117.
25. LeCun, Y., Bengio, Y., Hinton, G. (2015) Deep learning. *Nature* 521(7), 436444.

26. Caliskan, A., Yuksel, M.E., Badem, H., Basturk, A. (2017). A deep neural network classifier for decoding human brain activity based on magnetoencephalography. *Elektronika ir Elektrotechnika* 23(2), 63-67.
27. Batrk, A., Yksei, M.E., Badem, H., Alkan, A. (2017). Deep neural network based diagnosis system for melanoma skin cancer. In: 2017 25th Signal Processing and Communications Applications Conference (SIU), pp. 1-4
28. Caliskan, A. (2019).Emg sinyalleri için hibrid öznitelik çıkarma yöntemi geliştirilmesi.Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi 8(2), 652-664
29. Grozdic, D.T., Jovicic, S.T., Subotic, M. (2017).Whispered speech recognition using deep denoising autoencoder. *Engineering Applications of Artificial Intelligence* 59, 15- 22.
30. Xu, J., Xiang, L., Liu, Q., Gilmore, H.,Wu, J., Tang, J., Madabhushi, A. (2016). Stacked sparse autoencoder (SSAE) for nuclei detection on breast cancer histopathology images. *IEEE Transactions on Medical Imaging* 35(1), 119-130.
31. Zhang, J., Yan, C., & Gong, X. (2017). Deep convolutional neural network for decoding motor imagery based brain computer interface. 2017 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). doi:10.1109/icspcc.2017.8242581.
32. Bashivan, P., Bidelman, G. M., & Yeasin, M. (2014). Spectrotemporal dynamics of the EEG during working memory encoding and maintenance predicts individual behavioral capacity. *European Journal of Neuroscience*, 40(12), 3774-3784
33. Tjepkema-Cloostermans, M.C., de Carvalho, R.C., van Putten, M.J. (2018). Deep learning for detection of focal epileptiform discharges from scalp eeg recordings. *Clinical Neurophysiology* 129(10), 2191- 2196.
34. Golmohammadi, M., Harati Nejad Torbati, A.H., Lopez de Diego, S., Obeid, I., Picone, J. (2019).Automatic analysis of eegs using big data and hybrid deep learning architectures. *Frontiers in human neuroscience* 13, 76.
35. Yuan, Y., Xun, G., Ma, F., Suo, Q., Xue, H., Jia, K., Zhang, A. (2018).A novel channel-awareattention framework for multi-channel eeg seizure detection via multi-view deep learning. In: 2018 IEEE EMBS International Conference on Biomedical Health Informatics (BHI), pp. 206-209.
36. Acharya, U.R., Oh, S.L., Hagiwara, Y., Tan, J.H., Adeli, H. (2018).Deep convolutional neural network for the automated detection and diagnosis of seizure using eeg signals. *Computers in Biology and Medicine* 100, 270 – 278.
37. Ullah, I., Hussain, M., ul Haq Qazi, E., Aboalsamh, H. (2018).An automated system forepilepsy detection using eeg brain signals based on deep learning approach. *ExpertSystems with Applications* 107, 61- 71.

38. OShea, A., Lightbody, G., Boylan, G., Temko, A. Investigating the impact of cnn depth on neonatal seizure detection performance. (2018). 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 5862-5865. IEEE
39. Turner, J., Page, A., Mohsenin, T., Oates, T. (2014). Deep belief networks used on high resolution multichannel electroencephalography data for seizure detection. In: 2014 AAAI Spring Symposium Series.
40. Thodoro, P., Pineau, J., Lim, A. (2016). Learning robust features using deep learning for automatic seizure detection. In: Machine learning for healthcare conference, pp. 178-190.
41. Golmohammadi, M., Ziyabari, S., Shah, V., de Diego, S.L., Obeid, I., Picone, J. (2017). Deep architectures for automated seizure detection in scalp eegs. arXiv preprint
42. Golmohammadi, M., Ziyabari, S., Shah, V., Von Weltin, E., Campbell, C., Obeid, I., Picone, J. (2017). Gated recurrent networks for seizure detection. In: 2017 IEEE Signal Processing in Medicine and Biology Symposium (SPMB), pp. 1-5. IEEE.
43. Shah, V., Golmohammadi, M., Ziyabari, S., Von Weltin, E., Obeid, I., Picone, J. (2017). Optimizing channel selection for seizure detection. In 2017 IEEE Signal Processing in Medicine and Biology Symposium (SPMB), pp. 1-5. IEEE.
44. Ansari, A.H., Cherian, P.J., Caicedo, A., Naulaers, G., De Vos, M., Van Huffel, S. (2019). neonatal seizure detection using deep convolutional neural networks. *International Journal of Neural Systems* 29(04), 1850011.
45. O'Shea, A., Lightbody, G., Boylan, G., Temko, A. (2017). Neonatal seizure detection using convolutional neural networks. In: 2017 IEEE 27th International Workshop on Machine Learning for Signal Processing (MLSP), pp. 1-6. IEEE.
46. OShea, A., Lightbody, G., Boylan, G., Temko, A. (2020). neonatal seizure detection from raw multi-channel eeg using a fully convolutional architecture. *Neural Networks* 123, 12-25.
47. Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., Liu, C. (2018). A survey on deep transfer learning. *International conference on artificial neural networks*, pp. 270-279. Springer
48. Krizhevsky, A., Sutskever, I., Hinton, G.E. (2012). Imagenet classification with deep convolutional neural networks. In: F. Pereira, C.J.C. Burges, L. Bottou, K.Q. Weinberger (eds.) *Advances in Neural Information Processing Systems 25*, pp. 1097-1105. Curran Associates, Inc.
49. Lecun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE* 86(11), 2278-2324.

50. He, K., Zhang, X., Ren, S., Sun, J. (2015). Deep residual learning for image recognition
51. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. (2015). Going deeper with convolutions. In: Computer Vision and Pattern Recognition (CVPR).
52. INIK, O., ULKER, E. (2017). Derin renme ve grnt analizinde kullanlan derin renme modelleri.
53. Huang, G., Liu, Z., Weinberger, K.Q. (2016). Densely connected convolutional networks. CoRR abs/1608.06993.



## DİZİN

**A**

Abstract · v  
 Alexnet · 5  
 Anavo · 14  
 Analiz · 14

**B**

Boyut · 4  
 Bipolar · 6  
 Baskı · 36, 42

**C**

CNN · v, 10, 5, 16

**Ç**

Çizelge · ix, 4, 10, 11,  
 13, 14, 15, 16, 20

**D**

Densenet · 6  
 Deneysel · 9  
 Dizin · 50  
 DNN · v, 2, 5, 16

**E**

EEG · 3  
 Evrişim · 4  
 EKLER · 26

**F**

FCNN · xvi, 16

**G**

Giriş · 1  
 Googlenet · 6

**H**

Homojen · 13

**İ**

İçindekiler · vii

**K**

Kabul ve Onay · v  
 Key Words · 25, 65, 66

**L**

literatür · 11, 14, 29

**N**

Neural Network · iv, v

**O**

Optimizasyon · 2, 9

**Ö**

Özet · iv  
 Önişleme · 8  
 Özgeçmiş · 35

**P**

parametre · 4  
 p-DCNN · v, iv

**R**

Resnet18 · 5  
 Resnet50 · 5

**S**

Simgeler ve kısaltmalar ·  
 xvi  
 SVM · 16  
 Sonuçlar ve tartışma ·  
 31

**Ş**

Şekil · 5, 6, 7, 9, 10, 12,  
 13, 15, 17, 19

**T**

Teşekkür · vi

**V**

Veri Kümesi · 7  
 Varyans · 13

**Y**

Yöntem · 4



**TEKNOVERSİTE**



teknoversite **AYRICALIĞINDASINIZ**

**İSTE**

