



**GRAF DÖNÜŞÜMLÜ DERİN ÖĞRENME İLE EKG
SİNYALLERİNİN SINIFLANDIRILMASI**

**2023
DOKTORA TEZİ
BİLGİSAYAR MÜHENDİLİĞİ ANABİLİM DALI**

Gökhan KUTLUANA

**Tez Danışmanı
Doç. Dr. İlker TÜRKER**

**GRAF DÖNÜŞÜMLÜ DERİN ÖĞRENME İLE EKG SINYALLERİNİN
SINIFLANDIRILMASI**

Gökhan KUTLUANA

**Tez Danışmanı
Doç. Dr. İlker TÜRKER**

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Doktora Tezi
Olarak Hazırlanmıştır**

**KARABÜK
Kasım 2023**

Gökhan KUTLUANA tarafından hazırlanan “GRAF DÖNÜŞÜMLÜ DERİN ÖĞRENME İLE EKG SİNYALLERİNİN SINIFLANDIRILMASI” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Doç. Dr. İlker TÜRKER
Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 10/11/2023

<u>Ünvanı, Adı SOYADI (Kurumu)</u>	<u>İmzası</u>
Başkan : Doç. Dr. Caner ÖZCAN (KBÜ)
Üye : Doç. Dr. İlker TÜRKER (KBÜ)
Üye : Dr. Öğr. Üyesi Yusuf KURTGÖZ (KBÜ)
Üye : Prof. Dr. Ergin YILMAZ (BEÜN)
Üye : Doç. Dr. Aytaç ALTAN (BEÜN)

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Doç. Dr. Zeynep ÖZCAN
Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Gökhan KUTLUANA

ÖZET

Doktora Tezi

GRAF DÖNÜŞÜMLÜ DERİN ÖĞRENME İLE EKG SİNYALLERİNİN SINIFLANDIRILMASI

Gökhan KUTLUANA

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Doç. Dr. İlker TÜRKER

Kasım 2023, 102 sayfa

Biyolojik sistemler, sosyal ağlar, besin ağları, bilgisayar ağları ve daha birçok karmaşık sistemi ifade etmek için kullanılan graflar, günümüzde yapay zekâ alanında bir temsil yöntemi olarak da yaygın bir kullanım alanı bulmaktadır. Özellikle bu karmaşık sistemler ile ilgili karşılaşılabilecek makine öğrenmesi problemlerinin çözümünde graf ve graf özelliklerinden yararlanılmaktadır. Zaman serilerinden olan EKG, EEG, EOG ve EMG gibi çeşitli biyomedikal sinyaller biyolojik durum ve rahatsızlıkların tespit edilmesi ve sınıflandırılması için gerekli veri altyapısını sağlarlar. Görünürlük grafları ise zaman serisi verilerinin bazı temel sinyal özelliklerinin graf olarak temsil edilmesine olanak sağlamakta, bu özelliğiyle kullanımı gittikçe artan bir dönüşüm yöntemi olarak öne çıkmaktadır.

Bu tez çalışmasında, çok boyutlu bir zaman serisi olarak nitelendirilebilecek 12-derivasyonlu EKG'nin graf temsillerinden elde edilen komşuluk matrisi diyagonalleri

ve düğüm ağırlık dizisi özellik setlerinin ResNet ve Inception ağı modellerine girdi olarak verilerek grafların EKG sinyallerini temsil yeteneği araştırılmıştır. Çalışmada 21801 kayıttan oluşan PTB-XL veri seti kullanılmıştır. PTB-XL veri seti üst tanı, alt tanı, form ve ritim kategorilerinde yer alan 71 farklı EKG durumunu içermektedir. Üst tanı durumları dikkate alınan çalışmada çoklu-etiket sınıflandırma gerçekleştirilmiştir. ResNet ve Inception ağı modelleri özellik setlerinin farklı kombinasyonları için tek kanallı ve çok kanallı olarak oluşturulmuş ve her bir deneme 10 kez tekrar edilmiştir.

Veri setleri üzerinde gerçekleştirilen sınıflandırma denemelerinde komşuluk matrisinin ilk 3 diyagonalinin giriş verisi olarak kullanıldığı ResNet ağı modeli, orijinal sinyal, düğüm ağırlıkları ve farklı giriş verisi kombinasyonlarına oranla daha üstün bir sınıflandırma başarısı göstermiştir. Çoklu-etiket sınıflandırmada kullanılan başarı metriği olan AUC değeri dikkate alındığında, tez çalışması kapsamında elde edilen en yüksek değer olan %93,46 ile bu veri seti için daha önce gerçekleştirilen çalışmalardan daha yüksek bir sınıflandırma başarısı elde edilmiştir. Böylece graf tabanlı sınıflandırmanın geleneksel yöntemlerden daha iyi sonuç verme potansiyeli ortaya koyulmuştur.

Anahtar Sözcükler : EKG sınıflandırma, Derin öğrenme, Ağırlıklı görünürlük grafi, Karmaşık ağlar.

Bilim Kodu : 92410

ABSTRACT

Ph. D. Thesis

CLASSIFICATION OF ECG SIGNALS WITH GRAPH TRANSFORMED DEEP LEARNING

Gökhan KUTLUANA

**Karabük University
Institute of Graduate Programs
Department of Computer Engineering**

Thesis Advisor:

Assoc. Prof. Dr. İlker TÜRKER

November 2023, 102 pages

Graphs, which are used to represent biological systems, social networks, food networks, computer networks and many other complex systems, are now widely used as a representation method in the field of artificial intelligence. In particular, graphs and graph properties are used to solve machine learning problems that may arise in these complex systems. Various biomedical signals such as ECG, EEG, EOG and EMG, which are time series, provide the necessary data infrastructure for the detection and classification of biological conditions and disorders. Visibility graphs, on the other hand, allow some basic signal properties of time series data to be represented as a graph, and with this feature, it stands out as an increasingly used transformation method.

In this thesis, the ability of graphs to represent ECG signals is investigated by giving the adjacency matrix diagonals and node weight sequence feature sets obtained from

graph representations of 12-lead ECG, which can be considered as a multidimensional time series, as input to ResNet and Inception network models. The PTB-XL dataset consisting of 21801 records was used in the study. The PTB-XL dataset contains 71 different ECG conditions in the categories of upper diagnosis, lower diagnosis, form and rhythm. Multi-label classification was performed in the study considering the upper diagnostic conditions. ResNet and Inception network models were created as single-channel and multi-channel for different combinations of feature sets and each trial was repeated 10 times.

In the classification experiments performed on the datasets, the ResNet network model, in which the first 3 diagonals of the adjacency matrix were used as input data, showed a superior classification success compared to the original signal, node weights and different input data combinations. Considering the AUC value, which is the success metric used in multi-label classification, the highest value of %93.46, which is the highest value obtained within the scope of this thesis, has achieved a higher classification success than previous studies for this dataset. Thus, the potential of graph-based classification to provide better results than traditional methods has been demonstrated.

Key Word : ECG classification, Deep learning, Weighted visibility graph, Complex networks.

Science Code : 92410

TEŞEKKÜR

Bu tez çalışmasının planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda desteğini esirgemeyen, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren sayın hocam Doç. Dr. İlker TÜRKER 'e teşekkürlerimi sunarım.

Tez çalışması sürecinde bilimsel ve akademik anlamda desteklerini esirgemeyen tez izleme komitesindeki değerli hocalarım Doç. Dr. Caner ÖZCAN ve Dr. Öğr. Üyesi Yusuf KURTGÖZ 'e teşekkür ederim.

Hayatımın her aşamasında sabırla bana maddi ve manevi destek veren sevgili eşim Özlem KUTLUANA ve biricik kızım Hazal KUTLUANA 'ya tüm kalbimle teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xiv
SİMGELER VE KISALTMALAR DİZİNİ	xvi
BÖLÜM 1	1
GİRİŞ	1
1.1. LİTERATÜR ÖZETİ.....	4
1.2. ÇALIŞMANIN LİTERATÜRE KATKISI.....	10
BÖLÜM 2	11
ELEKTROKARDİYOĞRAFI	11
2.1. ELEKTROKARDİYOGRAM	11
2.2. ELEKTROKARDİYOGRAM ÖLÇÜMÜ.....	13
2.2.1. 12-Derivasyon EKG Ölçümü	13
2.2.1.1. Ekstremitte Derivasyonları	14
2.2.1.2. Göğüs Derivasyonları	15
BÖLÜM 3	17
ZAMAN SERİLERİNİN AĞ DÖNÜŞÜMÜ.....	17
3.1. Zaman Serisi.....	17
3.2. Ağ Dönüşümü Yöntemleri	19
3.2.1. Kompleks Ağlar	19
3.2.2. Görünürlük Ağları	22

	<u>Sayfa</u>
3.2.3. Diğer Ağ Dönüşümü Yaklaşımları	24
3.2.3.1. Geçiş Ağları	24
3.2.3.2. Yakınlık Ağları	27
BÖLÜM 4	30
EVİRİŞİMSEL SİNİR AĞLARI ve DERİN ÖĞRENME	30
4.1. Yapay Sinir Ağları	30
4.2. Derin Öğrenme	33
4.2.1. Evrişimsel Sinir Ağları (CNN)	35
4.2.1.1. Giriş Katmanı	36
4.2.1.2. Evrişim Katmanı	36
4.2.1.3. Düzeltme (RELU) Katmanı	37
4.2.1.4. Havuzlama (Pooling) Katmanı	38
4.2.1.5. Tam Bağlantılı (Fully-Connected) Katman	38
4.2.1.6. Sınıflandırma (Softmax) Katmanı	39
4.2.1.7. Seyreltme (Dropout) Katmanı	39
4.2.2. Sınıflandırma Performansı Ölçütleri	39
4.3. CNN Mimarileri	42
4.3.1. ResNet CNN Mimarisi	42
4.3.2. Inception CNN Mimarisi	45
BÖLÜM 5	47
VERİ SETİ VE AĞ DÖNÜŞÜMÜ İLE ÖZELLİK ÇIKARIMI	47
5.1. PTB-XL Veri Seti	47
5.2. Ağ Dönüşümü ile Özellik Çıkarımı	51
5.2.1. Komşuluk Matrisi Köşegenleri Kullanılarak Özellik Çıkarımı	51
5.2.2. Ağırlıklı Düğüm Dereceleri ile Özellik Çıkarımı	55
BÖLÜM 6	57
SINIFLANDIRMA UYGULAMASI	57
6.1. Sınıflandırıcı Modeller	57
6.2. Sınıflandırma Denemeleri ve Sonuçları	60
6.2.1. Orijinal Veri ile Sınıflandırma	61

	<u>Sayfa</u>
6.2.2. Standartlaştırılmış Orijinal Veri ile Sınıflandırma	63
6.2.3. Düzüm Ağırlıklı Derece Verileri ile Sınıflandırma	64
6.2.4. Ağırlıklı Komşuluk Matrisi Diyagonalleri ile Sınıflandırma	66
6.2.4.1. İlk Diyagonal Verisi ile Sınıflandırma	67
6.2.4.2. İlk 2 Diyagonal Verisi ile Sınıflandırma	69
6.2.4.3. İlk 3 Diyagonal Verisi ile Sınıflandırma	70
6.2.4.4. İlk 4 Diyagonal Verisi ile Sınıflandırma	71
6.2.4.5. İlk 5 Diyagonal Verisi ile Sınıflandırma	72
6.2.5. Orijinal Veri ile Komşuluk Matrisi ilk Diyagonalini kullanarak Sınıflandırma	74
6.2.6. Orijinal Veri ile Düzüm Ağırlıklı Dereceleri ile Sınıflandırma	76
BÖLÜM 7	80
SONUÇLARIN ANALİZİ VE ÖNERİLER.....	80
KAYNAKLAR	87
ÖZGEÇMİŞ	102

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1.	Kalbin iletim sistemindeki unsurları..... 12
Şekil 2.2.	EKG dalga morfolojisi [116] 12
Şekil 2.3.	12-Derivasyon EKG 14
Şekil 2.4.	Einthoven üçgeni 14
Şekil 2.5.	Ekstremitte derivasyonları ve dikey düzlemde kalbin bu derivasyonlara göre görünümü [118] 15
Şekil 2.6.	Göğüs derivasyonlarının yatay ekseninde görünümü [115] 16
Şekil 3.1.	Çeşitli zaman serisi örnekleri [122] 18
Şekil 3.2.	(a) Yönsüz graf örneği, (b) Yönlü graf örneği, (c) Yönsüz graftan elde edilen ağırlıklı komşuluk matrisi 20
Şekil 3.3.	(a) Çok katmanlı ağ örneği($V = 1,2,3,4,5$ ve $L1 = A, B$ ve $L2 = X, Y$), (b) Çoklu ağ örneği ($V = 1,2,3,4,5$) [19]..... 22
Şekil 3.4	(a) Doğal görünürlük ağ örneği,(b) Yatay görünürlük ağ örneği [19].. 23
Şekil 3.5.	Çeyrelik ağ dönüşümü örneği [19] 25
Şekil 3.6.	Sıralı bölme geçiş ağları $w=3$ ve $\tau=2$ için ağ dönüşüm örneği [19] 26
Şekil 3.7.	Kaba-taneli faz uzayı graf Örneği. Düğüm ve bağlantılar($w=5$, $\tau=2$ için) [127] 27
Şekil 4.1.	Sinir hücre yapısı ve sinaps bağlantıları [133]..... 30
Şekil 4.2.	Yapay sinir ağ örneği..... 31
Şekil 4.3.	Yapay sinir hücresi [134]..... 31
Şekil 4.4.	Sigmoid ve Tanh aktivasyon fonksiyonları 32
Şekil 4.5.	Bir CNN ağının genel yapısı [153] 36
Şekil 4.6.	$d=1$ kanallı görüntü evrişim işlemi 37
Şekil 4.7.	3 boyutlu ivme ölçer verisi evrişim işlemi..... 37
Şekil 4.8.	2×2 filtre 2 adım kaydırma ile maksimum havuzlama [158]..... 38
Şekil 4.9.	Seyreltme yapılmış bir ağ örneği [161] 39
Şekil 4.10.	İyi (AUC = 0,9) ve tatmin edici (AUC = 0,65) özgüllük ve duyarlılık parametrelerine sahip bir ROC eğrisi örneği [163] 40

Sayfa

Şekil 4.11.	Doğruluk matrisi	41
Şekil 4.12.	ResNet blok diyagramı	43
Şekil 4.13.	ResNet50 ağ mimarisi [168]	44
Şekil 4.14.	ResNet1d_wang modeli [97]	44
Şekil 4.15.	Inception temel blok yapısı [165]	45
Şekil 4.16.	Inception CNN mimari örneği	45
Şekil 5.1.	PTB-XL üst tanılar ve bunlara bağlı alt tanılar [23].....	48
Şekil 5.2.	Örnek PTB-XL EKG sinyal ritimleri [114].....	49
Şekil 5.3.	Özellik seti olarak kullanılan bir komşuluk matrisinden çıkarılan ilk n köşegen.	52
Şekil 5.4.	PTB-XL orijinal veri ve n köşegen dönüşümleri sonucunda elde edilen özellik seti grafikleri	54
Şekil 5.5.	Dönüşümler sonucu elde edilen yeni özellik verileri (1-derivasyon) ...	56
Şekil 6.1.	Sınıflandırmada kullanılan ResNet ve Inception modelleri [177]	58
Şekil 6.2.	N-Kanallı ResNet ve Inception modelleri [177].....	59
Şekil 7.1.	Görünürlük grafiği temsillerinin komşuluk matrisinin ilk n köşegeni için sınıflandırma sonuçları. Her 10 denemeden sonra hesaplanan (a) F1-Skoru, (b) AUC Metrikleri	82
Şekil 7.2.	Komşuluk matrisinin ilk 3 köşegeni kullanılarak yapılan en iyi deneme sonucu oluşan doğruluk matrisi.	83

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 1.1. PTB-XL üst sınıf EKG durum sınıflandırma ile ilgili literatürdeki çalışmalar ve başarıları	9
Çizelge 5.1. PTB-XL üst tanı sınıfları ve kayıt sayıları.....	50
Çizelge 6.1. Orijinal veri ile gerçekleştirilen ResNet modeli sınıflandırma sonuçları.....	61
Çizelge 6.2. Orijinal veri ile gerçekleştirilen Inception modeli sınıflandırma sonuçları.....	62
Çizelge 6.3. Standartlaştırılmış veri ile gerçekleştirilen ResNet modeli sınıflandırma sonuçları.....	63
Çizelge 6.4. Standartlaştırılmış veri ile gerçekleştirilen Inception modeli sınıflandırma sonuçları	64
Çizelge 6.5. Düğüm ağırlıklı derece verileri ile gerçekleştirilen ResNet modeli sınıflandırma sonuçları	65
Çizelge 6.6. Düğüm ağırlıklı derece verileri ile gerçekleştirilen Inception modeli sınıflandırma sonuçları	66
Çizelge 6.7. İlk diyagonalden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.....	67
Çizelge 6.8. İlk diyagonalden oluşan özellik seti ile Inception modeli sınıflandırma sonuçları.....	68
Çizelge 6.9 İlk 2 diyagonalden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.....	69
Çizelge 6.10. İlk 3 diyagonalden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.....	70
Çizelge 6.11. İlk 3 diyagonalden oluşan özellik seti ile Inception modeli sınıflandırma sonuçları.....	71
Çizelge 6.12. İlk 4 diyagonalden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.....	72

Çizelge 6.13. İlk 5 diyagonalden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.....	73
Çizelge 6.14. İlk 5 diyagonalden oluşan özellik seti ile Inception modeli sınıflandırma sonuçları.....	74
Çizelge 6.15. Orijinal veri ile komşuluk matrisi ilk diyagonalinin birleşiminden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.....	75
Çizelge 6.16. Orijinal veri ile komşuluk matrisi ilk diyagonalinin birleşiminden oluşan özellik seti ile Inception modeli sınıflandırma sonuçları	76
Çizelge 6.17. Orijinal veri ile ağırlıklı düğüm derecelerinin birleşiminden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları	77
Çizelge 6.18. Orijinal veri ile ağırlıklı düğüm derecelerinin birleşiminden oluşan özellik seti ile Inception modeli sınıflandırma sonuçları.....	78
Çizelge 7.1. Test edilen tüm özellik setleri ve ağ modellerine ait sınıflandırma sonuçları.....	81
Çizelge 7.2. Mevcut çalışmanın sınıflandırma performansının yakın zamanda yapılan çeşitli çalışmalarla özet karşılaştırılması.....	84

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

Hz : hertz

t : zaman serisi zaman değişkeni

Y_t : t zamanındaki seri değeri

G : graf

V : düğüm dizisi

E : düğümler arası bağlantı dizisi

A : komşuluk matrisi

$w_{i,j}$: i ve j düğümleri arasındaki bağlantı ağırlığı

Q : çeyreklik

τ : zaman gecikmesi

w : pencere genişliği

S : sembol dizisi

Σ : toplam simgesi

σ : aktivasyon fonksiyonu

deg : derece fonksiyonu

lr : öğrenme oranı

SS : standart sapma

KISALTMALAR

EKG : Elektrokardiyogram

ResNet : Residual Network (Artık Ağ)

EEG : Elektroensefalogram

EMG : Elektromiyogram

EOG : Elektrokülografi

CNN : Convolution Neural Network (Evrışimli Sinir Ağı)

PTB : Physikalisch-Technische Bundesanstalt

AUC : Area Under Curve (Eğri Altında Kalan Alan)

RELU : Rectified Linear Activation Function (Doğrusal Aktivasyon Fonksiyonu)

GAP : Global Average Pooling (Evrensel Ortalama Havuzlama)

RNN : Recurrent Neural Network (Özyinelemeli Sinir Ağı)

LSTM : Long-Short Temp Memory (Uzun-kısa Süreli Bellek)

HAR : Human Activity Recognition (İnsan Hareket Algılama)

YSA : Yapay Sinir Ağları

BÖLÜM 1

GİRİŞ

Günümüzde gerçek dünyada var olan birçok karmaşık sistem, ağ gösterimi ile ifade edilebilmektedir. Ağ olarak ifade edilebilen sistemlere; biyolojik sistemler, sinir ağları, mekânsal oyunlar, genetik ağlar, bilimsel iş birliği ağları, sosyal ağlar, aktör ağları, bilgisayar ağları, besin ağları, elektrik şebekesi ağları ve linguistik ağlar ve daha birçok sistem örnek gösterilebilir [1–6]. Çeşitli ağ dönüşümü stratejileri sayesinde bu sistemler ile ilgili karşılaşılabilecek bazı makine öğrenmesi problemlerinin çözümünde ağa dayalı özelliklerden yararlanılabilmektedir. Yapılan çalışmalar incelendiğinde özellikle graf çekirdekleri (graf kernels), graf gömme (graph embeddings) ve graf evrişimli ağlar gibi yöntemlerin ağ sınıflandırmada sıklıkla kullanıldığı görülmektedir [7–16].

Zaman serileri de ağlar ile ifade edilebilen verilerdendir. Bu verilerin analizi, tıbbi, duyuşsal, fiziksel, meteorolojik, biyolojik, finansal alanlardaki çeşitli veri dizilerini karakterize etmek için hayati öneme sahiptir [17–21]. Biyomedikal alan, EKG, EEG, EOG, EMG gibi çeşitli sinyallerin biyolojik durum ve rahatsızlıkların tespit edilmesi ve sınıflandırması için kullanımına odaklanmaktadır [19,22–24].

EKG, kardiyolojik hastalıkların tanısında kullanılan bir araçtır. Günümüzde EKG verilerinin yorumlanması için bilgisayar tabanlı sistemler yaygın bir kullanım alanı bulmaktadır. Düşük maliyet, güvenilirlik, invazif olmayan yapı ve hızlı raporlama gibi birçok özelliği ile EKG sinyalleri, kardiyolojik hastalıklarının teşhisinde en sık kullanılan araç olmuştur [25,26].

EKG sınıflandırma metotları incelendiğinde, orijinal EKG sinyallerinden çıkarılan özelliklerin giriş verisi olarak kullanıldığı geleneksel yaklaşımlar, destek vektör makinaları, karar ağaçları, Naïve Bayes, lojistik regresyon, k-en yakın komşu gibi

sınıflandırma modellerinden oluşmaktadır [27–31]. Geleneksel yöntemler dışında derin öğrenme yaklaşımları olan CNN, RNN, RNN ağlarının farklı bir varyantı olan LSTM, ResNet, Inception ve VGGNET gibi transfer öğrenme ağları da popüler olarak kullanılmaktadır [32–38].

Sınıflandırma işleminden önce EKG verilerinden özellik çıkartımı yapmak için farklı yöntemler kullanılmaktadır. Bu yöntemlere EKG morfolojisi, sinyal dalgacık dönüşümleri, EKG verisinin istatistiksel özellikleri, hermit polinomu, güç spektral özellikleri ve güç spektral resimleri örnek olarak verilebilir [39–47].

Derin öğrenme teknikleri geleneksel makine öğrenmesi yöntemlerine oranla daha yüksek sınıflandırma başarılarına ulaşabilirken, aşırı öğrenmeyi önlemek için daha yüksek miktarda veriye ihtiyaç duyarak önemli ölçüde daha yüksek bellek ve hesaplama ayak izine sahiptirler [48]. Derin öğrenme modelleri, hiyerarşik mimarileri ile derin özellikleri yakalamaları ve geleneksel modellere nazaran sinyallerden daha iyi öznetelik çıkarmayı başarmaları sebebiyle daha yüksek sınıflandırma performansı gösterebilmektedirler [26].

Son yıllarda zaman serisi sinyal verilerinin sınıflandırmadan önce ağ yapısına dönüştürüldüğü yaklaşımlara ilgi kayda değer bir şekilde artmaktadır. Bu ilginin altında yatan neden sinyal verilerinin zamana bağlı ilişkisel özelliklerini yakalayabilmek ve bu şekilde ham veriden çıkartılamayan nitelikleri elde edebilmektir [49]. Ağ bilimindeki ilerlemelerin bir sonucu olarak, zaman serilerinin altında yatan dinamik davranışlar, sinyal alanında da uygulanabilen ağ gösterimleri aracılığıyla keşfedilebilir olmuştur [50–52]. Tekrarlanan veya karakteristik nitelikteki sinyal oluşumlarını ağ yaklaşımının daha iyi yansıttığı raporlanmıştır [53].

Zaman serisi verilerinin ağ dönüşümü için farklı yaklaşımlar bulunmaktadır. Bu yaklaşımlar zaman serisi verilerin tek kanallı ve çok kanallı sinyalleri için dönüşüm sağlamaktadır. Bu noktada görünürlük, geçişli ve yakınlık temelli yaklaşımlar bulunmaktadır. Görünürlük temelli yaklaşımlar, zamandaki her bir veri noktasının bir düğümü temsil ettiği ve bu düğümlerin doğrusal çizgilerle diğer düğümlere ait genlik barlarına takılmadan birbirini görmesi durumunda aralarında bağlantı kurulan doğal

görünürlük ağı [54] ve yatay görünürlük ağı [55] yöntemleridir. Bu iki yaklaşımın daha özel varyantları olan limitli penetre görünürlük ağı [56] ve ağırlıklı görünürlük ağı [57] da bulunmaktadır. Ağ dönüşümü için kullanılan diğer bir yaklaşım ise zaman uzayını ağın düğümleri olacak bir dizi geçici duruma veya parçaya bölerek tanımlanan durumlar arasındaki geçiş olasılıklarına dayanan çeyreklik ağları [23] ve sıralı parçalı geçiş ağlarıdır [58]. Bir diğer yaklaşım ise çok boyutlu faz uzayına dâhil edilen zaman serilerinin noktaları arasındaki mesafeyi hesaplamak için mesafe veya benzerlik ölçülerini kullanan yakınlık ağlarıdır. Bu ağ yaklaşımları korelasyon ağları [59], döngü ağları [60] ve yineleme ağlarıdır [61]. Çok kanallı zaman serilerinde ise tek kanallı ağ dönüşümleri her bir kanala ayrı ayrı uygulanmaktadır. Dönüşümlerin ardından oluşan ağlarda yer alan düğümlerin birbirleri ile kurdukları ilişkilerle çok kanallı sinyalleri temsil eden ağlar oluşturulabilmektedir [19]. Ayrıca doğrudan çok kanallı sinyallerin tek tek görünürlük ağları ile ifade edildiği ve oluşan ağların katmanlı şekilde temsil edildiği çok katmanlı görünürlük ağları da bu verileri temsil etmede kullanılmaktadır [62].

EKG dalga formu düzenli olarak tekrar eden periyodik sinyallerden oluşur. Sağlıklı bir kişinin EKG dalga şekli olan sinüs ritmi, R dalgaları arasındaki düzenli kalp atışlarını (R-R aralığı) gösterir ve kalbin elektriksel iletim sisteminin düzgün çalıştığını gösterir. Aritmiler, kalp yetmezliği ve iletim bozuklukları gibi kalbin elektriksel aktivitesindeki anormallikler, EKG dalga şeklinde düzensizliklere ve değişikliklere neden olarak sinyal karmaşıklığının artmasına yol açar [63–66]. Fiziksel aktivite seviyeleri, solunumdaki değişiklikler, duygusal durumlar ve ilaç kullanımı gibi fiziksel ve patolojik faktörler de EKG sinyal değişkenliğine neden olabilir [67,68]. Yüksek değişkenlik, kalbin elektriksel aktivitesindeki daha büyük bir karmaşıklığı yansıtır. Karmaşıklığın ve düzensizliğin arttığı durumlar, EKG dalga formundaki P dalgalarında, QRS komplekslerinde ve T dalgalarında morfolojik çeşitliliğe neden olur [43,45,69]. EKG düzenli periyodik sinyallerden oluşur ancak sinyal karmaşıklığı ve düzensizliği değişkenlik gösterebilir. Bununla birlikte, periyodik, rastgele ve fraktal zaman serisi verilerini analiz etmek için kullanılabilen görünürlük grafları, EKG'nin sinyal özelliklerini analiz etmek için bir yaklaşım olarak kullanılabilir [54,70].

Bu tez çalışmasında kardiyolojik rahatsızlıkların tespit edilmesinde önemli bir araç olan EKG sinyallerinin sınıflandırılmasında, ağ dönüşümü yaklaşımlarından olan ağırlıklı doğal görünürlük ağı, çok kanallı bir EKG veri seti olan PTB-XL veri setine [25] uygulanarak veriyi temsil eden bir ağ yapısı elde edilmiştir. Elde edilen ağ yapısı içerisinde yer alan düğümlerin ağırlık özellikleri ve ağ komşuluk matrisindeki diyagonal olarak ifade edilen derece komşulukları, sınıflandırmada kullanılacak özellikler olarak seçilmiştir. Çıkarılan özellikler standartlaştırma işlemine tabi tutularak sınıflandırma aşamasında kullanılmıştır. Bu özellikler, literatürde başarılı sonuçlar veren derin öğrenme mimarileri olan ResNet ve Inception modellerine girdi olarak verilmiş, elde edilen sınıflandırma başarısı literatürdeki diğer çalışmaların sonuçları ile karşılaştırılmıştır. Yapılan karşılaştırmalar sonucu ağ dönüşümü ile özellik çıkartma yaklaşımlarına tabi tutulan verilerin sınıflandırma işleminde daha başarılı sonuçlar verdiği tespit edilmiştir.

Bu tez çalışması yedi bölümden oluşmaktadır. Bölüm 1’de çalışmanın amacı ve organizasyonu, literatür özeti ve çalışmanın literatüre katkıları verilmiştir. Bölüm 2’de EKG’nin yapısı ve özellikleri ile ilgili bilgi verilmiştir. Bölüm 3’te graf teorisi ve karmaşık ağların genel özellikleri ve ağ dönüşümü yaklaşımlarının detayları verilmiştir. Bölüm 4’te yapay öğrenme ve derin öğrenme ağları ile ilgili detaylar verilmiştir. Bölüm 5’te, kullanılan EKG veri seti ve özellik çıkartımı için kullanılan metotlarla ilgili bilgi verilmiştir. Bölüm 6’da gerçekleştirilen sınıflandırma uygulamasıyla ilgili detay bilgiler ve uygulama sonuçları verilmiştir. Bölüm 7’de ise çalışma kapsamında elde edilen sonuçların değerlendirmesi yapılmış ve geleceğe dair önerilere yer verilmiştir.

1.1. LİTERATÜR ÖZETİ

EKG, insanın cilt yüzeyine yerleştirilen elektrotlar vasıtasıyla kalbin elektriksel aktivitelerine ait voltaj değerlerini zamana karşı gösteren bir grafikdir [71]. Kardiyolojik rahatsızlıkların belirlenmesi ve kalbin durumu hakkında detaylı bir bilgi elde edilmek için kullanılan önemli bir tanı aracıdır. EKG’de elde edilen veriler ile hastanın sağlıklı olup olmadığı, sağlıklı değil ise kalpteki atriyal fibrilasyon,

miyokardiyal enfarktüs, hipertrofi, ST çökmesi, iletim bozukluğu, taşikardi vb. ritim bozuklukları tespit edilebilmektedir [72].

Standart bir EKG, her biri ayrı elektrotlardan gelen sinyal kayıtlarının tanımladığı 12 derivasyondan oluşmaktadır (I, II, III, avR, avL, avF, V1, V2, V3, V4, V5, V6 vb.). 12 derivasyondan oluşan EKG'nin bütünlük ve çeşitlilik olmak üzere iki doğal özelliği vardır. Kalbin farklı uzaysal açılarından elde edilen elektriksel aktivitelerle kalbin genel durumu hakkında bilgi içerirken, kalbin farklı anatomik bölgelerine karşılık gelen derivasyonlar spesifik bilgiler içermektedir [73].

EKG verilerinin sınıflandırılmasında geleneksel makine öğrenmesi ve derin öğrenme yaklaşımları yaygın bir şekilde kullanılmaktadır. Geleneksel yaklaşımlarında ilk olarak özellik çıkartma ve ardından sınıflandırma işlemleri gerçekleştirilmektedir. EKG verisini temsil eden özellikleri çıkarmak için farklı yaklaşımlar mevcuttur. Sinyallerin yerel spektral ve zamansal bilgilerinin çıkartıldığı dalgacık dönüşümü ile yapılan çalışmalar [74–76], verilerin istatistiksel özelliklerinin çıkarıldığı çalışmalar [77–80], EKG'nin sinüs formlu sinyal yapısındaki morfolojik (şekilsel) özelliklerin çıkartıldığı çalışmalar [69,81], yüksek boyutlu EKG sinyallerini düşük boyutlu sinyallere dönüştürerek bilgilerin elde edildiği bağımsız bileşen analizi, temel bileşen analizi ve doğrusal ayırma analizi ile ilgili çalışmalar [82–84] bulunmaktadır. Ayrıca özelliklerin çıkartılmasındaki başarıyı artırmak için optimizasyon temelli özellik seçimi de çalışmalarda kullanılmaktadır [81,85].

Özellik çıkarma işleminin ardından sınıflandırma aşamasında EKG için birçok geleneksel yaklaşım kullanılmaktadır. Destek vektör makinaları [27,86–88], karar ağaçları [89,90], k-en yakın komşu [39,91] ve Naïve Bayes sınıflandırıcıları gibi makine öğrenmesi yaklaşımları yaygın bir şekilde kullanılmaktadır [28].

EKG sinyallerinin sınıflandırılmasında geleneksel makine öğrenmesi yöntemlerine alternatif olarak, günümüzde derin öğrenme modelleri de sinyallerden daha iyi öznitelik çıkarma kapasiteleri ve daha yüksek sınıflandırma performansı göstermeleri sebebiyle yaygın bir kullanım alanına sahip olmuştur. Evrişimsel sinir ağları (CNN) en temel derin öğrenme tekniklerinden biridir. CNN ile yapılan sınıflandırma

çalışmalarına örnek olarak Zhao vd.'nin 2020 yılında dalgacık dönüşümü ve 24 katmanlı bir CNN ağıyla softmax sınıflandırıcısını kullandığı çalışması [46], Baloğlu vd.'nin 2019 yılında 12-derivasyonlu EKG'den miyokardiyal enfarktüs rahatsızlığının tespit edilmesinde CNN kullandığı çalışması [38], Muayed vd.'nin 2020 yılında EKG sinyallerini resimlere dönüştürerek 2 boyutlu CNN ağ yapısı ile sınıflandırdığı çalışması [92] verilebilir.

CNN yaklaşımı dışında zaman serisi verilerinin ardışıl ve birbiriyle bağlantılı olmasını en iyi şekilde sınıflandırabilecek ağların başında RNN ve bu modelin kısa süreli bellek problemini çözen ve verinin ağ boyunca taşınmasını sağlayan LSTM gelmektedir[93]. Sumaiya vd. tarafından 2021'de EKG'ye dayalı depresyon risklerini RNN ve LSTM ağları ile belirledikleri çalışması [94], Sampath ve Sumithira'nın 2022'de EKG verisindeki tanımlayıcı noktalar olan P-QRS-T tepelerini uyarlamalı eşikleme tekniği ile tanımladığı ve RNN-CNN ağları ile sınıflandırarak başarısını geleneksel yöntemlerle kıyasladığı çalışması [95] örnek olarak verilebilir. Ayrıca CNN ve LSTM yaklaşımlarının hibritlenerek kullanıldığı çalışmalar da bulunmaktadır [96–98]. CNN mimarisi dışında karmaşık ağların eğitimini kolaylaştıran, artık ağ olarak adlandırılan ve giriş verisinin diğer katman bloklarına hızlı bir şekilde yayılmasını sağlayan özelliği ile karmaşıklığı artan yapılarda performansı iyileştiren ResNet bulunmaktadır [99]. Strothoff vd. 2021'de bir EKG veri seti olan PTB-XL için derin öğrenme yöntemlerini test ettiği çalışmasında ResNet başarılı sonuçlar vermiştir [32]. Ayrıca aynı çalışmada, ağda hem yerel alana özgü özelliklerin çıkartılması hem de genel özelliklerin çıkartılmasında etkili bir model olan Inception modeli de başarılı sınıflandırma sonuçları vermiştir.

Zaman serisi verilerinin ağ dönüşümü için kullanılan birçok yaklaşım bulunmaktadır. Bu yaklaşımlar, biyomedikal alanda özellikle EKG ve EEG gibi sinyallerin analiz edilmesi çalışmalarında kullanılmaktadır. M. McCullough vd.'nin 2017'de sıralı bölme ağları ile EKG sinyallerindeki dinamik değişiklikleri belirledikleri çalışması [100], Zhang ve Small'un 2006'da döngü ağları dönüşümü ile oluşan ağın topolojik özellikleri ile sağlıklı ve sağlıklı insanlar arasındaki farkları EKG açısından belirledikleri çalışması [101], Kulp vd. 'nin 2016'da sıralı bölme ağlarını, sağlıklı ve sağlıklı hastalardaki çeşitli kardiyolojik hastalıkların tespit edilmesinde kullandıkları

çalışması [58], Li vd.'nin 2021'de atriyal fibrilasyon ritimlerini ağırlıklı çoklu ölçeklenebilir penetre görünürlük ağları ile keşfettikleri çalışması [17], Ma vd.'nin 2020'de çoklu görünürlük ağları ile sağlıklı ve miyokardiyal enfarktüs rahatsızlığına sahip hastaları ağ özellikleri ile tanımladıkları çalışması [102], ağ dönüşümlü EKG çalışmalarına örnek olarak verilebilir.

EEG verilerinde ise görünürlük ağ dönüşümlerinin yaygın bir kullanımı söz konusudur. Bu çalışmalara örnek olarak, Ahmadlou vd.'nin 2010'da Alzhemier hastalığının tanımlanmasında görünürlük ağlarını kullandıkları [103], Wang vd.'nin 2016'da yine Alzheimer hastalığının tanısında sınırlı görünürlük ağlarını kullandıkları [104], Pineda vd.'nin 2020'de EEG sinyallerinin tanımlanmasında çeyreklik ağlarını kullandıkları [23], Zhu, Li ve Wen'in 2014'te görünürlük ağlarının farklarından yararlanarak uyku durumlarını tanımladıkları [105] çalışmaları verilebilir. Buna karşılık EKG verilerinde görünürlük ağları ile ilgili çalışmaların literatürde görece daha az olduğu görülmektedir.

Bu tez çalışmasında kullanılacak EKG veri seti belirlenirken özellikle derin ağlarda kullanım için daha uygun olan yüksek hacimli veri içerenler üzerinde durulmuştur. Ayrıca veri miktarı yüksek olan veri setleri, kalp ile ilgili daha fazla tanı ve durumu içereceğinden daha kapsamlı bir çözüm elde edilmesine olanak tanımaktadır. Bu kapsamda, tez çalışması için uygun olduğu değerlendirilen 12 derivasyonlu EKG veri setleri; Chapman Üniversitesi ve Shaoxing Halk Hastanesinin himayesinde oluşturulan, 10646 hastanın 11 temel ritim ve 67 kardiyolojik durumunu içeren, 500Hz örnekleme frekansı ile kaydedilen ve uzmanlar tarafından etiketlenen veri seti [106], Çin'de bulunan 11 hastanedeki 9458 bireyden toplanan ve toplamda 9831 kaydın 500 Hz örnekleme frekansı ile elde edildiği CPSC2018 veri seti [107], ve 21837 EKG kaydını içeren 100HZ ve 500HZ örnekleme frekansları bulunan ve 71 farklı EKG durumunu içeren ve kayıtların uzman kardiyologlar tarafından etiklendiği PTB-XL [25] veri setidir. Ayrıca farklı veri setlerinin kombinasyonlarından oluşan ve EKG sinyallerinin sınıflandırması ile ilgili yarışmalar için geliştirilmiş veri setleri de bulunmaktadır [108,109].

Çalışmada veri seti olarak PTB-XL seçilmiş ve kullanılmıştır. PTB-XL veri setinin kullanıma sebeplerinden biri, yeni bir veri seti olması nedeniyle literatürde üzerinde yapılan çalışmaların nispeten sınırlı olmasıdır. Ayrıca tek başına daha fazla veriyi sunması, verilerin farklı örnekleme frekanslarıyla üretilmiş olması ve daha fazla kardiyolojik durum içermesi de diğer önemli tercih sebepleridir. Güncel bir veri seti olması sebebiyle yakın zamanda yapılan, özellikle kalp rahatsızlıklarını tespitine yönelik derin öğrenme çalışmalarında da tercih edilmektedir [32,110–113].

PTB-XL veri seti üzerinde derin öğrenme ağları ile yapılan ilk çalışma Strodthoff vd.'nin yapmış olduğu ve derin öğrenme ağlarının farklı varyantlarının kullanıldığı çalışmadır. Bu çalışma hastaların cinsiyet açısından ikili sınıflandırıldığı, yaş açısından regresyon ile sınıflandırıldığı, EKG durumlarının üç farklı etiketleme yaklaşımı (alt sınıflar, üst sınıflar ve bütün sınıflar) için çoklu etiket olarak sınıflandırıldığı ve son olarak EKG sinyallerinin form ve ritimlere göre çoklu etiket olarak sınıflandırıldığı bir çalışmadır. PTB-XL veri seti içerisinde yer alan kayıtlar birden fazla sınıfa dahil olabilmektedir. Veri setindeki kayıtların çoklu etiket sınıf tanımlamasında dolayı sınıflandırmada ikili sınıflandırma kullanılmaktadır. İkili sınıflandırma problemleri için belli bir eşik (threshold) değerine göre sınıflar belirlendiği için en uygun sınıflandırma ölçütü olarak ROC-AUC kullanılmaktadır [114].

Strodthoff vd.'nin çalışması referans alınarak tez çalışmamızda da üst sınıf EKG etiketleri kullanılarak çok etiketli sınıflandırma yapılmıştır. Bu sınıflandırmada yer alan üst sınıflar *Normal*, *Hipertrofi*, *ST/T Değişimi*, *Miyokardiyal Enfarktüs* ve *İletim Bozukluğu* sınıflarıdır. Üst sınıf EKG durum sınıflandırması için literatürde gerçekleştirilen çalışmalar ve sınıflandırma başarıları Çizelge 1.1'de verilmiştir.

Çizelge 1.1'de yer alan çalışmalar içerisinde veri setinin hem orijinal hali hem de indirgenmiş hali ile yapılan çalışmalar bulunmaktadır. Veri setinin orijinal halinin korunduğu ve eğitim, doğrulama ve test verilerinin değiştirilmediği çalışmalar [32] ve [73]'dir. Bu çalışmalarda sınıf etiket tanımlaması yapılmayan kayıtlar dahil edilmemiştir. [115]'in tasarlamış olduğu çok katmanlı ve artık ağırlı evrimsel sinir

ađına global havuzlama katmanını eklediđi alıřma, %93,41 AUC deđeri ile orijinal verinin kullanıldıđı en bařarılı sınıflandırma alıřmasıdır.

izelge 1.1. PTB-XL üst sınıf EKG durum sınıflandırma ile ilgili literatürdeki alıřmalar ve bařarıları.

alıřma	Mimari	Veri Kullanımı	AUC	F1-Skoru
[32]	Resnet1d_wang	21430 kayıt (katlar 1-8 eđitim, 9 dođrulama, 10 test)	%93	-
[73]	MLBF-NET	21430 kayıt (katlar 1-8 eđitim, 9 dođrulama, 10 test)	%93,10	-
[115]	ST-CNN-GAP-5	21837 kayıt (katlar 1-9 eđitim (%88) + dođrulama (%12), 10 test)	%93,41	%79,28
[116]	CNN+ entropi zellikleri	17232 kayıt (%70 eđitim, %15 dođrulama, %15 test)	%91,00	%68,00
[110]	FSL+ Dođrusal ekirdekli DVM	17232 kayıt (%70 eđitim, %15 dođrulama, %15 test)	%93,80	%71,70
[113]	33-katmanlı CNN Mimarisi + NCBAM	21837 kayıt (%80 eđitim, %20 test)	%93,14	-
[117]	2D-CNN+DKR-block	21837 kayıt (katlar 1-8 eđitim, 9 dođrulama, 10 test)	%92,9	%77
[112]	11-layer CNN	17232 kayıt (%70 eđitim, %15 dođrulama, %15 test)	%90,3	%68

PTB-XL veri seti üst sınıf sınıflandırılması için oklu etiket sınıflandırması ile ilgili alıřmalar izelge 1.1’de yer alan alıřmalardır. Bu alıřmalar dıřında üst sınıfların gruplandırılarak ikili sınıflara dönüřtürüldüđü sınıflandırma alıřmaları da bulunmaktadır. Sharma ve Eskiciođlu 2022’de yapmıř oldukları alıřmada veri setindeki kayıtları normal olan EKG kayıtlar ile diđer kayıtlar olmak üzere iki ayrı sınıfa ayırmıřlardır. Raspberry PI ve TensorFlowLite ile 12-derivasyonun tamamı üzerinde gerekleřtirmiř oldukları sınıflandırma denemesinde %81,21’lik dođruluk metriđi deđerine ulařmıřlardır[118]. Hammad vd. 2022’de gerekleřtirmiř oldukları bir diđer alıřmada oklu etiket ieren kayıtların filtrelendiđi ve 17232 veriden oluřan yeni kayıtlarla sınıflandırma gerekleřtirdiđi alıřması bulunmaktadır. Bu alıřmada kayıtların %70’i eđitim, %30’u test verisi olarak sınıflandırmaya tabi tutulmuř ve bařarı metriđi olan dođruluk deđerine %99,20 ölçülmüřtür [119].

1.2. ÇALIŞMANIN LİTERATÜRE KATKISI

Gerçekleştirilen bu tez çalışmasında özellik setlerinin elde edilmesinde kullanılan ağırlıklı görünürlük graf dönüşümü, EKG sınıflandırmasına alternatif bir yaklaşım getirmektedir. Sinyallerde yer alan dalga örüntülerinin karakteristiğini ortaya koyma açısından orijinal sinyale kıyasla farklı bir temsil sunmaktadır. Elde edilen sonuçlar, orijinal sinyal ile yapılan derin öğrenme çalışmalarına kıyasla ağırlıklı ağ yaklaşımının daha yüksek sınıflandırma başarısı sunduğunu göstermektedir. Özellikle komşuluk matrisi ilk 3 diyagonal ile elde edilen özellik seti, kayda değer bir sınıflandırma başarısı göstermektedir.

Bu tez çalışmasında EKG verisi özelinde kullanılan metotlar, farklı zaman serisi verileri üzerinde de sinyal karakteristiklerini ortaya koyma potansiyeline sahiptir. Sinyal karakteristiğinin önemli olduğu EEG, EMG gibi biyomedikal sinyaller, HAR, endüstriyel sensör verileri, haberleşme sinyalleri, finansal seriler gibi alanlarda yer alan problemlerin çözümüne katkı sağlayabilir.

Çalışmada kullanılan veri seti olan PTB-XL son yıllarda literatüre sunulmuş olup emsallerine kıyasla yüksek hacimli oluşu ile öne çıkmaktadır. Bu veri setiyle EKG alanında gerçekleştirilmiş olan tez çalışmamız gelecek yıllarda aynı veri seti ile gerçekleştirilecek çalışmalara da referans olacaktır.

BÖLÜM 2

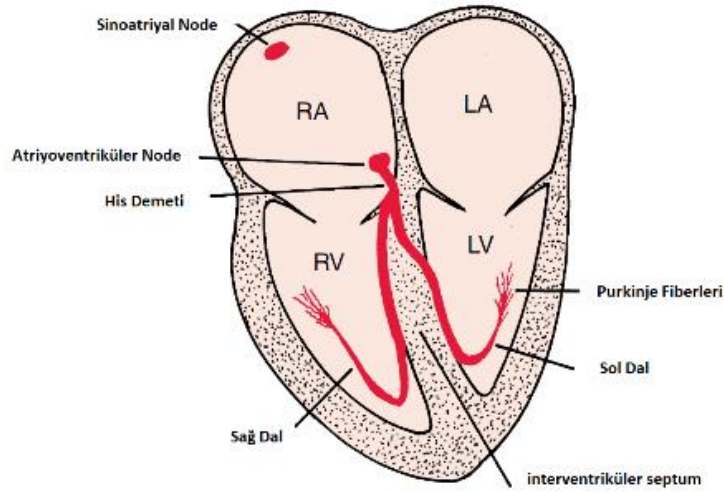
ELEKTROKARDİYOĞRAFI

2.1. ELEKTROKARDİYOGRAM

EKG vücudun çeşitli bölgelerindeki deri yüzeylerine, genel olarak sol ayak, sol kol, sağ kol ve göğüste kalbin hizasında yatay olarak önden arkaya doğru yerleştirilen elektrotlar vasıtası ile kalbin çalışması esnasındaki elektriksel aktiviteyi kaydeden bir yöntemdir. Kayıt işleminin grafiğe dönüştürülmesi ile de elektrokardiyogramlar oluşmaktadır. Oluşan elektrokardiyogramlar, kardiyolojik birçok rahatsızlığın tespit edilmesine yardımcı olmaktadır.


Kalbin iletim sistemi dört ana unsurdan oluşmaktadır. Kalbin ana uyarı kaynağı olan, belli aralıklarla uyarı üreten ve kalp hızını belirleyen sinoatriyal düğüm ilk unsurdur. Burada oluşan uyarı ilk olarak sağ atriyuma, daha sonra da sol atriyuma geçer. Sinoatriyal düğümden sonra başlayan uyarı atriyum ve ventriküllerin kesiştiği yerde bulunan ve görevi ventrikülleri atriyallerin aşırı hızından korumak olan atriyoventriküler düğüm bulunmaktadır. Atriyoventriküler düğümün ardından uyarıların ventriküllerin distal kısımlarına ulaşmasını sağlayan bir yol olan his demetleri yer almaktadır. His demetlerinin ardından elektriksel uyarının ventriküllerin içinde hızlı yayılmasını ve ventriküllerin kasılmasını sağlayan Purkinje fiberleri bulunmaktadır [120]. Şekil 2.1’de kalbin iletim sistemindeki unsurlar verilmiştir.

Elektrokardiyogram grafiklerinin oluşumu sinoatriyal düğümden itibaren Purkinje fiberlerine olan süreçte elektriksel aktivitenin ölçülmesi ile oluşmaktadır. Bu aşamada kalp kas hücrelerinin elektriksel yüklerindeki değişimlerle sinyal verileri oluşmaktadır. İnsan hücreleri iyon konsantrasyonlarının yardımı ile hücre zarlarının içinden dışarıya doğru mikro volt ile mili volt arasında elektrik üretirler. Tıpkı bir batarya gibi çalışmaktadırlar.



Şekil 2.1. Kalbin iletim sistemindeki unsurları [120].

Kalp kası hücreleri dinlenme anında hücre içi ve dışındaki yüklerin dengeli olduğu polarize durumdadır. Hücre içi negatif, hücre yüzeyi pozitif yüklüdür. Bu hücrelerin elektriksel olarak uyarılması ile hücre içinin tamamen pozitif, hücre yüzeyinin ise tamamen negatifi döndüğü duruma depolarizasyon denir. Hücre depolarizasyon durumundan bir süre sonra tekrar dinlenme durumuna geçmektedir. Buna repolarizasyon denir. Elektriksel uyarımın atriyaller ve ventriküller boyunca yayılması ve dinlenme durumuna dönülmesi ile EKG grafikleri oluşmaktadır [121,122]. EKG dalga morfolojisi Şekil 2.2’de verilmiştir.



Şekil 2.2. EKG dalga morfolojisi [121].


Atriyallerin uyarılması ve depolarize olması ile P dalgası oluşmaktadır. Ventriküllerin uyarılması ve depolarize olmasıyla QRS kompleksi oluşmaktadır. Belli bir süre geçtikten sonra ventriküllerin repolarizasyonu ile ST segmenti, T dalgası ve U dalgası oluşmaktadır.

2.2. ELEKTROKARDİYOGRAM ÖLÇÜMÜ

İnsan vücudu, her bölgesinde elektriği iletme yeteneği sahiptir. Bu nedenle vücudun çeşitli noktalarına elektrotlar yerleştirilerek kalp akımlarının voltajları saptanabilmektedir. Vücudun farklı bölgelerine yerleştirilen elektrotlar vasıtasıyla kalbin elektriksel aktivitesi farklı bakış açıları ile değerlendirilebilmektedir. Vücudun farklı noktalarına yerleştirilen elektrotlar arasındaki voltaj farkları ise derivasyon olarak tanımlanmaktadır. Elektrokardiyogram sinyal verilerini oluşturmak için standart olarak 12 derivasyonlu EKG ölçümü kullanılmaktadır [121,123].

2.2.1. 12-Derivasyon EKG Ölçümü


12-derivasyon EKG ile vücudun uzuvlarına ve göğüs kısmına yerleştirilen 10 farklı elektrot ile kalbin 12 farklı elektriksel durumunun ölçümü sağlanmakta ve bu ölçümler farklı açı ve düzlemlerde dalga formuna dönüştürülmektedir [123]. Bu derivasyonlar, uzuvlar arası elektriksel voltaj farklılıklarının ölçüldüğü I, II, III, aVR, aVL ve aVF uzuv (ekstremit) derivasyonları ile göğüs kafesinde yer alan 6 farklı yerleşimdeki elektrotlar arasındaki voltaj farklılıklarının ölçüldüğü V1, V2, V3, V4, V5, V6 göğüs derivasyonları olmak üzere 2 kısma ayrılır [121]. Şekil 2.3'te 12-derivasyon EKG'ye ait sinyal formasyonu verilmiştir.



Şekil 2.3. 12-Derivasyon EKG.

2.2.1.1. Ekstremitte Derivasyonları

Ekstremitte derivasyonlarında kalbin elektriksel aktivitesini sol-sağ el ve sol ayak bileklerine bağlanan bipolar elektrotlar kullanılarak elektrotlar arasındaki voltaj farkları ölçülmektedir. Sağ ayağa takılan elektrot ile de topraklama yapılmaktadır. I, II, III olmak üzere 3 derivasyondan oluşmaktadır. Bu üç derivasyon, ismini elektrokardiografiyi icat eden Hollandalı fizikçi Einthoven'den alarak Einthoven üçgeni olarak adlandırılmaktadır. Einthoven üçgeni Şekil 2.4'te verilmiştir.



Şekil 2.4. Einthoven üçgeni.


Einthoven üçgeninde LA kalbin sol elde yer alan elektrota gönderdiği elektriksel voltajı, RA sağ ele gönderdiği elektriksel voltajı ve LL ise sol ayağa gönderdiği voltajı ölçmektedir. Derivasyon I, II, III kalbin ön düzlem formları hakkında bilgi verir [121,123]. Derivasyonlar sırasıyla kalbi dikey düzlemde 0° , 60° , 90° 'lik açılarla gözlemler. Eşitlik 2.1, 2.2 ve 2.3'te derivasyon voltaj fark formülleri verilmiştir.

$$I = LA - RA \quad (2.1)$$

$$II = LL - RA \quad (2.2)$$

$$III = LL - LA \quad (2.3)$$

Ekstremitte derivasyonlarının bir diğeri de artırılmış ekstremitte derivasyonlarıdır. 1930'lı yıllarda göğüs kafesi derivasyonlarının ardından Dr. Emanuel Goldberger tarafından bulunmuştur. Çift kutup başlı elektrotların başka bir uç noktadaki elektrotta göre ölçüm yapmasının aksine tek kutuplu elektrotlar potansiyeli sifıra yakın bir elektrotta göre ölçüm yapmaktadır. Artırılmış ekstremitte derivasyonlarının elektrotların bulunduğu noktadan kalbe baktığı varsayılır. aVR, aVL ve aVF olarak adlandırılan artırılmış ekstremitte derivasyonları sırasıyla kalbi dikey düzlemde -30° , 30° , 90° derecelik açılarla gözlemler [120,123]. Şekil 2.5'te Ekstremitte derivasyonları ve dikey düzlemde kalbin elektriksel aktivitelerinin derivasyonlara göre görünümü verilmiştir.

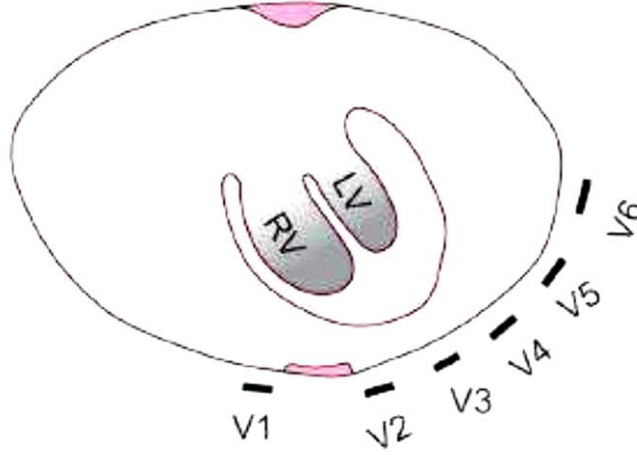


Şekil 2.5. Ekstremitte derivasyonları ve dikey düzlemde kalbin bu derivasyonlara göre görünümü [123].

2.2.1.2. Göğüs Derivasyonları

Göğüs derivasyonları göğüs kafesinde belirli yerlere yerleştirilerek yatay düzlemde kalbi önden arkaya doğru sarar. V1, V2, V3, V4, V5, V6 olmak üzere toplam 6 adet

bipolar kutuplu elektrotlardan oluşmaktadır. Yatay düzlemde V1 ve V2 derivasyonu sağ ventrikülü, V3 ve V4 derivasyonu ventriküller septumu, V5 ve V6 sol ventrikülü görür. Kalbin arkasına inceleme yapılacaksa yeni elektrotların bağlanması gerekir [121]. Şekil 2.6'da Göğüs derivasyonlarının yatay ekseninde yerleşimi verilmiştir.



Şekil 2.6. Göğüs derivasyonlarının yatay ekseninde görünümü [120].

BÖLÜM 3

ZAMAN SERİLERİNİN AĞ DÖNÜŞÜMÜ

Zaman serisi, zaman içinde birbirini izleyen eşit aralıklı noktalarda alınan bir dizidir. Zaman serileri istatistik, sinyal işleme, örüntü tanıma, ekonometri, matematiksel, finans, hava tahmini, deprem tahmini, elektroensefalografi, elektrokardiyografi astronomi ve büyük ölçüde zamansal ölçümleri içeren birçok alanında kullanılmaktadır [124,125]. Zaman serilerinin analizinde verinin doğrusal olması ve doğrusal olmamasına göre farklı yaklaşımlar bulunmaktadır. Gerçek dünyada elde edilen birçok zaman serisi verisi hem doğrusal olmayan yapıda hem de yüksek boyutludur. Bu verilerin analizi için ağ bilimi temelli bazı yaklaşımlar bu verilerin yapısını anlamak için yeni öngörüler ve yeni bakış açıları sunmaktadır [19]. Bu bölümde zaman serilerinin ağ dönüşümüne dair bilgiler verilmiştir.

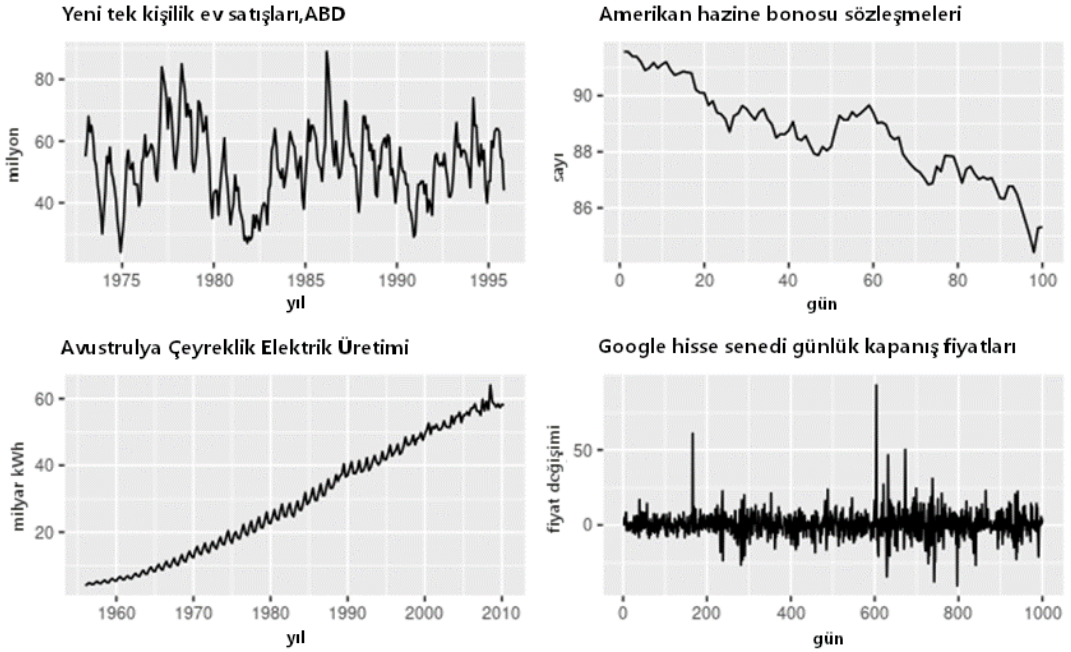
3.1. Zaman Serisi

Biçimsel olarak, bir $Y = (Y_1, \dots, Y_t)$ zaman serisi, t zamanı tarafından indekslenen $\{Y_t\}_t$ rasgele değişkenlerin bir dizisi olan stokastik bir sürecin veya tamamen açık bir matematiksel ilişki ile temsil edilebilen dinamik bir deterministik sürecin sonlu bir gerçekleşmesidir. Zaman serilerinin ana karakteristiği, birçok geleneksel istatistiksel yöntemin uygulanabilirliğini sınırlayan gözlemler arasındaki seri bağımlılıktır. Zaman serisi analizi, tahmin ve simülasyon amacıyla veri özelliklerinin makul açıklamalarını sağlayan matematiksel modellerdir. Ve seri korelasyonların ortaya çıkardığı istatistiksel problemleri sistematik olarak çözmek için geliştirilen prosedürlerdir [19,125].

Zaman serisi analizi için verilen temel istatistiksel araçlar; ortalama fonksiyonu, farklı zamanlardaki değişkenler arasındaki bağımlılıkları ölçen oto kovaryans, bir t zamanındaki seriyi, s zamanındaki değerden yaklaşık olarak tahmin eden

oto korelasyondur. Zaman serisi içerisinde tahmin, öngörü ve analizlerin tutarlı olması için serinin durağan olması gerekir. Durağanlık zaman serisi verilerinin belirli bir zaman sürecinde sürekli artma veya azalmanın olmadığı, verilerin zaman boyunca bir yatay eksen boyunca saçılım gösterdiği biçimde tanımlanır. Ortalama, kovaryans ve varyans zaman boyunca sabit kalıyorsa seri durağandır [19]. Temelde en basit zaman serisi süreci beyaz gürültüdür. Beyaz gürültü durağan olmayan serilerde hata terimi olarak kullanılmaktadır.

Tek değişkenli zaman serisi verileri bir t zamanı boyunca ölçülen Y_t değerleridir. Çok değişkenli zaman serileri bir vektör tarafından bir t zamanı boyunca $Y_t = (Y_{1,t}, Y_{2,t}, \dots, Y_{m,t})'$ ile ifade edilir. Çok değişkenli zaman serilerinin analizi standart istatistiksel yöntemlerden farklı olmalıdır. Bu nedenle çok değişkenli zaman serileri için doğrusal ve doğrusal olmayan modeller özel olarak geliştirilmiştir [126]. Şekil 3.1'de çeşitli zaman serisi örnekleri verilmiştir.



Şekil 3.1. Çeşitli zaman serisi örnekleri [127].

3.2. Ağ Dönüşümü Yöntemleri

Zaman serisi verilerinin ağ dönüşümü graf temelli yaklaşımlar kullanılmaktadır. Bu yaklaşımlar görünürlük grafları, geçiş ağları yakınlık ağlarıdır.

3.2.1. Kompleks Ağlar

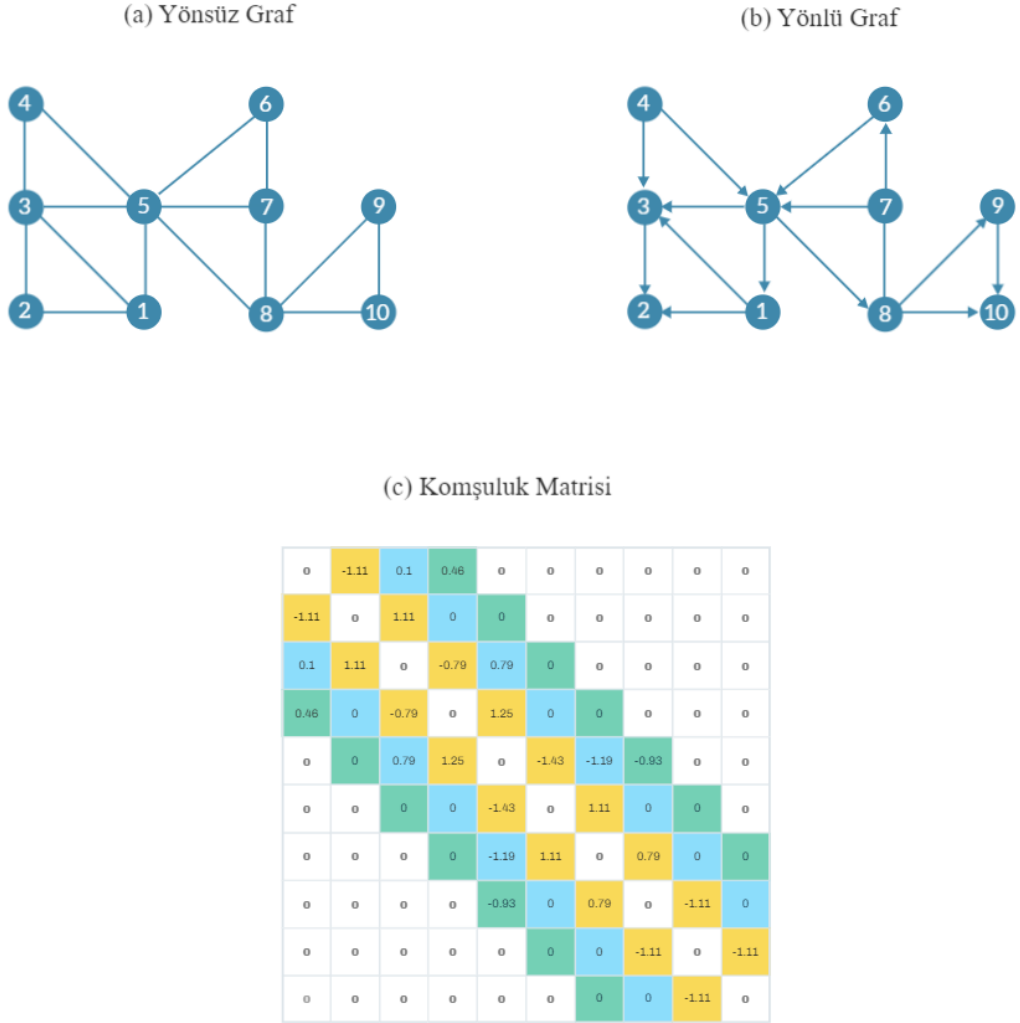
Kompleks ağlar doğa ve toplumda yer alan birçok sistemi tanımlar. Örnek olarak internet, sosyal ağlar, biyolojik ağlar, web sayfaları, toplumsal ilişkiler ve sinir sistemindeki nöronlar ve bunlar arasındaki iletişim verilebilir [6]. Graflar bu sistemlerde yer alan elemanları düğüm ve arasındaki ilişkileri bağlantı olarak tanımlayan ve kompleks sistemleri en iyi şekilde ifade etmek için kullanılan yapılardır.

Matematiksel olarak bir ağ, graf olarak ifade edilir. Bir graf V ve E çiftinin kümesinden $G = \{V(G), E(G)\}$ oluşur. V grafını oluşturan N adet düğümden oluşan düğümler dizisi $V = \{V_1, V_2, V_3, \dots, V_N\}$, grafta yer alan düğümler arasındaki bağlantılar (link, kenar) kümesi ise E ile ifade edilir. Grafta yer alan iki düğüm v_i ve v_j olmak üzere, eğer $(v_i, v_j) \in E(G)$ ise bu düğümler bağlantılıdır. Graftaki düğümler arasındaki bağlantılar karşılıklı ise yönsüz, aksi durumda yönlü graf olarak adlandırılmaktadır. Düğümler birbirine bağlanırken belli ağırlık değerleri kullanılarak bağlanırsa graf ağırlıklı graftır.

Graflar düğüm ve bağlantıları içeren komşuluk matrisleri ile ifade edilir. Komşuluk matrisi A olmak üzere düğümler arası bağlantılar eğer $(v_i, v_j) \in E(G)$ ise $A_{i,j} = 1|w_{i,j}$, yok ise 0 değerini almaktadır. Şekil 3.2’de örnek graflar verilmiştir.

Grafları oluşturan yapılar olan düğüm, düğümler arası bağlantılar ve bağlantılarla oluşan komşuluk matrisleri, kompleks ağların analiz edilmesinde ve bu ağlarla ilgili önemli bilgilerin elde edilmesinde kullanılmaktadır. Kullanılan bu yapılarla ağla ilgili bilgi veren çeşitli ağ parametreleri hesaplanabilmektedir. Bu parametrelerin bir kısmı ağın geneli ile ilgili bilgi verirken, bir kısmı da düğüm ve düğüm bağlantısallıkları ile ilgili bilgileri vermektedir. Bir zaman serisi verisi olan EKG ile ilgili yapılan bu

çalışmada temel parametreler olan düğüm, bağlantı, komşuluk matrisi ve derece parametreleri ve bunların özellikleri kullanılmış ve aşağıda verilmiştir.




Şekil 3.2. (a) Yönsüz graf örneği, (b) Yönlü graf örneği, (c) Yönsüz graftan elde edilen ağırlıklı komşuluk matrisi.

- **Düğüm (Node):** Ağ içerisinde her bir nokta veya eleman düğüm olarak adlandırılır. Zaman serisi verileri için zaman ekseninde her bir veri noktasını temsil etmektedir [19].
- **Bağlantı (Edge):** Düğümler arasındaki ilişkilerden ortaya çıkan bağlantılardır. Bağlantılar yönlü/yönsüz ve ağırlıklı/ağırlıksız olabilmektedir. Örneğin bir

EKG sinyali içerisinde ardışık olan iki veri noktası birbirleriyle bağlantı kurabilir [17].

- **Komşuluk Matrisi (Adjacency Matrix):** Bağlantı matrisi olarak da ifade edilen komşuluk matrisi, ağ içerisindeki bütün düğümler arasındaki bağlantıların varlığını ve yokluğunu gösteren kare şeklinde bir matristir [128]. Düğüm çiftleri arasında (v_i, v_j) ; $A_{i,j} = 0$ (bağlantı yok), $A_{i,j} = 1$ (bağlantı var) ve $A_{i,j} = w_{i,j} \in \mathbb{R}$ (ağırlıklı bir bağlantı var) durumları gözlenebilir.
- **Derece (Degree):** Derece parametresi ağda yer alan her bir düğümün diğer düğümlerle kurmuş olduğu bağlantı sayısını ifade etmektedir. Komşuluk matrisinde her bir düğümün bulunduğu satırda bulunan değerler toplamı, o satırdaki düğümün derecesini vermektedir. Derece değeri yönlü ağlarda düğüme gelen ve düğümden giden bağlantılar için ayrı ayrı hesaplanmaktadır [2,6].

Birçok gerçek dünya sistemi alt sistemlerden oluşabilir ve diğer dış sistemlerle bağlantılı olabilir. Bunun neticesinde farklı alt sistemler ve dış sistemlerden elde edilen veriler sistemi anlamada yardımcı olabilir. Bu verilerin analiz edilmesi normal tek katmanlı ağ yapılarına göre daha farklı yaklaşımlar olan çok katmanlı ağlarla gerçekleştirilebilir [19]. Çok katmanlı ağlar, tek katmanlı ağ yaklaşımını da kullanarak farklı özelliklerle oluşturulabilecek tek katmanlı farklı ağlar arasındaki düğümlerin birbirine bağlanabildiği ve her katmanda yer alan düğümlerin birbirlerinin alt kümesi olduğu bir ağ yapısıdır [129]. Çok katmanlı ağ, $L = \{L_\alpha\}_{\alpha=1}^s$ temel katmanlar (α her bir katman görünümünü, s ise görünümlerin sayısını), olmak üzere, $M = (V_m, E_m, V, L)$ formülü kullanılarak olarak tanımlanır. V, M ağının düğümleri olmak üzere, $V_m \subset V \times L_1 \times L_2 \times \dots \times L_s$ temel katman yer alan düğümlerim düğüm-katmanlı kombinasyonlarının kümesidir. $E_m \subset V_m \times V_m$ ise, temel katmanların ve olası çift düğümlerin kombinasyonlarını içeren kenar kümesidir [129]. $s=1$ değeri için çoklu ağ yapısı oluşmaktadır. Şekil 3.3'te çok katmanlı ağlara ve çoklu ağlara örnek verilmiştir.

(a) Çok Katmanlı Ağ ($s=2$)(b) Çoklu Ağ ($s=1$)

Şekil 3.3. (a) Çok katmanlı ağ örneği ($V = \{1,2,3,4,5\}$ ve $L_1 = \{A, B\}$ ve $L_2 = \{X, Y\}$), (b) Çoklu ağ örneği ($V = \{1,2,3,4,5\}$) [19].

3.2.2. Görünürlük Ağları

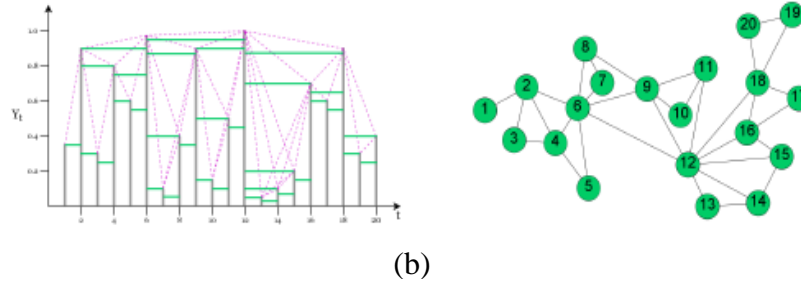

Zaman serilerinin ağ dönüşümü için görünürlük, geçişlilik ve yakınlık temelli yaklaşımlar bulunmaktadır. Ve çeşitli zaman serisi çalışmalarında bu yaklaşımlar kullanılmıştır [130]. Silva vd. 2021’de yapmış oldukları çalışmada bu yaklaşımlar hakkında detaylı bilgiler vermiştir [19]. Bu yaklaşımlardan biri de görünürlük ağlarıdır. Görünürlük Ağları zaman serisi içerisinde her bir veri noktası için ağ yapısında bir düğüm oluşturur. Bu düğümler zaman serisi içerisinde sıralı bir şekilde seçilmektedir. Ağ yapısı içerisindeki bağlantılar ise bu sıralı düğümler arasında bir çizgi çekildiğinde herhangi düğüm aradaki görünürlüğü engellemiyorsa bağlantı oluşturulur ve sıralı bir şekilde bütün düğümler gezilerek aralarında tanımlanan bağlantılar ağ yapısına dâhil edilir [54].

Bağlantılar arasındaki görünürlük (3.1) eşitsizliği ile kontrol edilir ve $\{V_i\}$ ve $\{V_j\}$ düğümleri arasında bu eşitsizlik sağlanıyorsa bağlantı oluşturulur. Bir başka deyişle (t_k, Y_k) bir zaman – genlik ikilisi ve $t_i < t_k < t_j$ zamanda farklı noktaları temsil etmek üzere eşitlik 3.1’de ifade edilen eşitsizliğin sağlanması, i ve j düğümleri arasında bir bağlantı tanımlanması gerektiğini gösterir.

$$Y_k < Y_j + (Y_i - Y_j) \cdot \frac{(t_j - t_k)}{(t_j - t_i)} \quad (3.1)$$

Formül ile verilen görünürlük bağlantıları doğal görünürlük ağı için kullanılmaktadır. Yatay görünürlük ağ bağlantıları için ise i ve j düğümleri arasında yer alan ve $t_i < t_k < t_j$ şartını sağlayan bütün (t_k, Y_k) zaman-genlik ikililerinin eşitlik 3.2'deki şartı da sağlaması durumunda i ve j düğümleri arasında bağlantı tanımlanır.

$$Y_i, Y_j > Y_k \quad (3.2)$$



Şekil 3.4 (a) Doğal görünürlük ağ örneği, (b) Yatay görünürlük ağ örneği [19].

Yatay görünürlük ağları, doğal görünürlük ağlarının bir alt kümesi gibi düşünülmekte ve daha yerel özelliklerin incelendiği durumlarda tercih edilebilmektedir [19]. Bu iki temel görünürlük ağı dışındaki diğer görünürlük ağ yaklaşımları aşağıda verilmiştir.

- **Limitli Penetre Görünürlük Ağı:** Limitli penetre görünürlük ağı, yatay t zaman ekseninde veri noktaları arasındaki görünürlük şartının bir l uzunluğu ile kısıtlanarak bağlanabilirliği sınırlandıran, görünürlük ağlarının farklı bir yaklaşımıdır [56]. Eşitlik 3.3'te hesaplama formülü verilmiştir.

$$Y_{i+l} < Y_j + (Y_i - Y_j) \cdot \frac{t_j - (t_j - t_l)}{(t_j - t_i)}, \quad l < j - i \quad (3.3)$$

- **Yönlü Görünürlük Ağı:** Bağlantıların zamanda soldan sağa doğru ilerleyerek yönlü olarak oluşturulduğu yaklaşımdır [131].
- **Ağırlıklı Görünürlük Ağı:** Ağırlıklı görünürlük ağı yönlü ve ağırlıklı bir ağ oluşturulmasını sağlamaktadır. Ağ içerisindeki düğümler arasındaki ağırlık iki nokta arasındaki bir görüş açısı ile temsil edilmektedir [57]. (t_i, Y_i) ve (t_j, Y_j) iki veri noktası ve $w_{i,j}$ iki nokta arasındaki ağırlık olmak üzere görüş açısı formülü eşitlik 3.4'te verilmiştir.

$$w_{i,j} = \alpha_{i,j} = \tan^{-1}\left(\frac{Y_j - Y_i}{t_j - t_i}\right), \quad i < j \quad (3.4)$$

Formül ile elde edilen ağırlıklar negatif ve pozitif değerler alabilmektedir. Negatif ağırlıklar noktalar arasında azalan bir trendin, pozitif değerler ise noktalar arasındaki artan bir trendin göstergesidir [19].

- **Fark Görünürlük Ağı:** Fark görünürlük ağı doğal görünürlük ile yatay görünürlük ağlarının bağlantı kümelerinin birbirinden çıkarılması ile elde edilmektedir [105].

3.2.3. Diğer Ağ Dönüşümü Yaklaşımları


Görünürlük temelli yaklaşımlar dışında zaman serisi noktalarını temsil etmek üzere atanan sembol geçiş kavramına dayanan geçiş ağları ve çok boyutlu zaman serisi veri noktaları arasındaki mesafe ve benzerliklerle oluşturulan yakınlık ağları bulunmaktadır.

3.2.3.1. Geçiş Ağları

Geçiş ağları, seriyi temsil etmek üzere atanan semboller arasındaki geçiş kavramına dayalı olarak zaman serilerinden oluşturulan bir ağ türüdür. İlk adım olarak zaman içindeki ardışık veriler çeşitli yöntemlerle sembollere dönüştürülür. Ardından


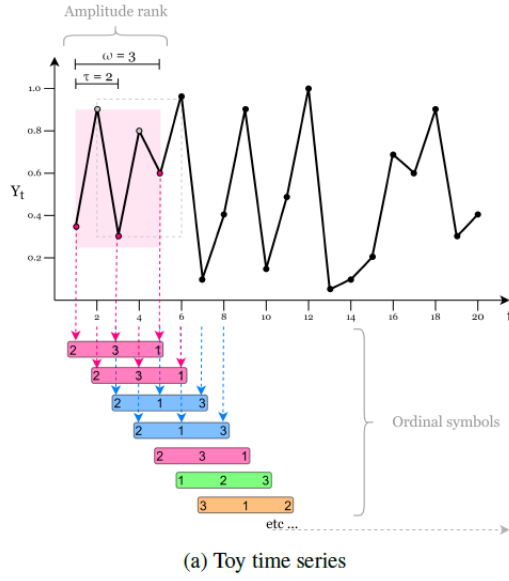
belirlenen bir geçiş fonksiyonu ile semboller düğümüne ve geçiş işlemi de bağlantılara dönüştürülerek ağ dönüşümü gerçekleştirilir. Çeyreklik Ağları [23], Sıralı Bölme Geçiş Ağları [58], Kaba-Taneli Faz Uzayı Grafları [132] ve Görünür Grafçık Ağları [133] geçiş ağlarına örnek olarak verilebilir.

Çeyreklik ağları zaman serisi gözlem verilerinin genlik değerlerinin çeyreklik değerlere dönüştürülerek ardışık olarak birbirine bağlanması ile oluşturulan bir ağıdır. Bu ağ içerisinde her bir çeyreklik nicelikleri Q ile ifade edilmektedir. (q_1, q_2, \dots, q_Q). Her bir çeyreklik niceliği q_i ağın düğümlerini oluşturmaktadır. v_i ve v_j düğümleri çeyreklikler arasındaki geçiş olasılığını temsil eden ağırlıklarla (v_i, v_j, w_{ij}) birbirine yönlü olarak bağlanmaktadır [134]. Şekil 3.5'te çeyreklik ağlarına ait bir görsel verilmiştir.



Şekil 3.5. Çeyreklik ağ dönüşümü örneği [19].

Sıralı bölme geçiş ağları zaman serisi gözlemlerinin bir dizi ardışık desen olarak tanımlandığı ve oluşan desenlerin ardışık olarak birbirlerine bağlanması ile oluşan bir ağ yapısıdır. Bu ağ yapısında semboller tek kanal zaman serisi üzerinde belirlenen bir pencere genişliği w ve zaman gecikmesi τ parametreleri ile belirlenen noktaların değer büyüklük sırası vektöründen oluşmaktadır. $\pi_i = (R_1, R_2, \dots, R_w)$, $R_j \in \{1, 2, \dots, w\}$, $R_j \neq R_k \Rightarrow j \neq k$ ile desenler formülize edilmektedir. Ağın düğümlerini desenler, bağlantılarını ise birbirini takip eden desenler oluşturmaktadır. Şekil 4'te Sıralı bölme geçiş ağlarının desen dönüşümü ve oluşan ağ yapısı verilmiştir [23].




Şekil 3.6. Sıralı bölme geçiş ağları $w=3$ ve $\tau=2$ için ağ dönüşüm örneği [19].

Kaba-Taneli Faz Uzayı grafları zaman serisi verisini tıpkı sıralı bölme geçiş ağ dönüşümünde olduğu gibi belirlenen bir w pencere genişliği ve τ zaman gecikmesi ile $D=w$ boyutunda bir sembol dizisi vektörüne dönüştürerek ağ için düğümleri oluşturur. Ardışık τ zaman gecikmesi ile oluşan her bir sembol dizisi kendisinden sonra gelenle bağlantı kurarak ağdaki bağlantılar yönlü olarak oluşturulmaktadır [132]. Wang vd. 2016'da yapmış oldukları çalışmada ardışık zaman serisi veri noktaları arasındaki farkları ($p(t)=X(t)-X(t-1)$) kullanarak hesapladıkları bir M_p değerini referans ($M_p > m_p > 0$) olarak sembol kümesi düğüm dönüşümünü gerçekleştirmektedir. $S=\{R, r, e, d, D\}$ kümesindeki semboller eşitlik 3.5'teki formüle göre düğüme dönüştürülmektedir. Çalışmada m_p eşik değeri 0 olarak belirlenmiştir [132].

$$S = \begin{pmatrix} R, M_p < p(t) \\ r, m_p < p(t) \leq M_p \\ e, -m_p \leq p(t) \leq m_p \\ d, -M_p \leq p(t) < m_p \\ D, p(t) < -M_p \end{pmatrix} \quad (3.5)$$

Oluşan örnek sembol dizisi ve bağlantılar Şekil 3.7'de verilmiştir.



Şekil 3.7. Kaba-taneli faz uzayı graf örneği. Düşüm ve bağlantılar($w=5$, $\tau=2$ için) [132].

Görünür grafçık ağları zaman serisi verilerinin belirlenen bir w pencere genişliği ve τ zaman gecikmesi olmadan iteratif olarak verinin sonuna doğru kaydırılarak her bir kaydırmada veriye ait bir grafçığın elde edildiği, ardından bu grafçıkların aynı komşuluk matrisine sahip olanlarının tekil hale getirilerek tekil grafçıklar arasındaki bağlantıların frekansları açısından incelenmesini sağlayan bir ağ dönüşümü yaklaşımıdır [135].

3.2.3.2. Yakınlık Ağları

Yakınlık ağları, çok boyutlu faz uzayına katılmış zaman serisi veri noktalarının arasındaki mesafe ve benzerlik ölçülerini kullanarak ağ dönüşümünü gerçekleştirmektedir. Bu yöntem veri noktalarının durumlarını düğüme, düğümler arasındaki mesafe ve benzerlik değerlerini de bağlantılara dönüştürür. Çevrim ağları [60], korelasyon ağları [59], yineleme ağları [61] bu ağlara örnek olarak verilebilir.

Çevrim ağları zaman serisi verilerini farklı uzunluklarda alt çevrimlere bölerek bu çevrimlerin her birinin düğüm olduğu ve bu çevrimler arasındaki bağlantılar belirlenirken varyans ve kovaryans istatistikleri ile oluşturulan korelasyon katsayısı değerinin kullanıldığı bir ağ dönüşümü yöntemidir. Farklı uzunluklardaki çevrimler arasında küçük olan çevrimin büyük olan çevrime göre kaydırılması ile elde edilen korelasyon katsayıları içinden en büyük olanı seçilmektedir. İki çevrim arasındaki bağlantılar bir eşik değer üzerinde ise bağlantı gerçekleşmektedir. Ve bu şekilde çevrimlerin düğüm, çevrimler arasındaki korelasyon katsayısı değerinin bağlantıları oluşturduğu bir ağ yapısı oluşmaktadır [19,101].

Bir diğer yaklaşım olan korelasyon ağlarında ise, zaman serisi verileri belirlenen bir w pencere uzunluğunda mümkün olan bütün alt parçaların ağda düğüm olarak tanımlandığı ve bu parçaların aralarındaki bağlantıların Pearson korelasyonu ile hesaplandığı ve belirlendiği bir ağ dönüşümü yöntemidir. Pearson korelasyon değerinin ± 1 arasında değerler alması sayesinde bu parçalar arasındaki negatif ve pozitif ilişkileri de ağda temsil edebilmeyi sağlamaktadır [59].

Yineleme ağları zaman serisi verilerinin belirlenen bir w -boyutlu faz uzayına dönüştürüldüğü ve her bir veri noktasının vektör olarak ifade edildiği ve bu noktaların serideki diğer noktalar ile olan ilişkilerinin bağlantıları oluşturduğu bir ağ dönüşümüdür. Her bir nokta $\vec{Z}_i = (X(t), X(t + \tau), \dots, X(t + \tau(w - 1)))$, $\tau=1$ olan vektör ile temsil edilmektedir ve ağda her bir vektör bir düğüme karşılık gelmektedir. Düğümler arası bağlantılar için i ve j seride iki nokta olmak üzere, \vec{Z}_i, \vec{Z}_j iki vektör arasında belirlenen bir uzaklığa göre (öklit, manhattan vb.) ve belli bir eşik değere göre belirlenmektedir ve ağ oluşturulmaktadır [61].

Yukarıda bahsedilen yaklaşımlar tek değişkenli zaman serileri için kullanılan ağ dönüşümü yaklaşımlarıdır. Çok değişkenli zaman serilerinde ise, birinci olarak zaman serilerini temsil eden düğümler ve bu düğümler arasındaki ilişkilerden örneğin korelasyon, nedensellik vb. oluşan bağlantılardan oluşan tek katmanlı ağ dönüşümü yaklaşımları, ikinci olarak ise her bir değişken serisinin tek katmanlı ağ yapısına dönüştürülerek oluşturulan çoklu katmanlı ağ dönüşümü yaklaşımları bulunmaktadır [19].

Çok deęişkenli zaman serilerindeki her bir deęişken serinin dięer deęişken seriler ile arasındaki baęlantılar; korelasyon ölçümleri, uzaklık ölçümleri, varyans ayrıştırması, geçiş olasılıkları ve gecikmeli neden regresyonu gibi deęerler kullanılarak elde edilmektedir. Çoklu katman aę dönüşümleri için ise görünürlük aęları ve yinelemeli aęlar ile deęişken serilerinin her biri bir aę katmanı olarak ifade edilmektedir. Bu katmanların hepsi bir araya gelerek çok katmanlı bir aę yapısını oluşturmaktadır [19].

Aę dönüşümü yaklaşımlarını incelediğimizde birçok yöntemin zaman serisi verilerinde var olan özelliklerin aęa aktarılmasında yetersiz kaldığı görülmektedir. Yerel veri noktalarının analiz edilmesinin önemli olduęu bir zaman serisi olan EKG için bu nokta özelliklerini aęa aktaracak aę dönüşümünün tercih edilmesi önemlidir. Bu yüzden tez çalışması için bu temsili en iyi gerçekleştirecek yöntem olan aęrıklı görünürlük aęları tercih edilmiş ve kullanılmıştır. Çok deęişkenli bir veri olan EKG verisi için analiz işleminin her bir derivasyon için ayrı yapılması önem arz etmektedir. Çok deęişkenli yöntemlerde deęişken serileri arasındaki ilişkiler baęlantıları oluşturmaktadır. Ve bu da deęişken serilerinden aęa önemli ayırt edici özelliklerin aktarımını engelleyici bir durum oluşturacağı ve veri temsili azaltacağı için tercih edilmemiştir.

BÖLÜM 4


EVRIŞİMSEL SİNİR AĞLARI ve DERİN ÖĞRENME

Çalışmamızda kullanılan EKG veri setinin özellik çıkartımı işleminin ardından sınıflandırıcı olarak derin öğrenme ağları kullanılmıştır. Bu bölümde yapay sinir ağları, derin öğrenme, CNN ve sınıflandırıcı olarak kullanılan derin öğrenme ağ modelleri ile ilgili bilgi verilmiştir.

4.1. Yapay Sinir Ağları


YSA, biyolojik sinir sistemi içerisindeki nöron hücrelerinin çalışmasının matematiksel olarak modellendiği ve çeşitli makine öğrenmesi problemlerinin çözümünde kullanılan bir yöntemdir. Sınıflandırma, kümeleme, örüntü tanıma, tahmin yapma ve optimizasyon vb. problemlerde yaygın bir kullanım alanı sunmaktadır [136]. Ses tanıma, radar ve sonar sinyallerinin sınıflandırılması, beynin modellenmesi çalışmaları, el yazısı tanıma, otomatik araç denetimi, meteorolojik yorumlama vb. çalışmalar kullanım uygulamalarına örnek olarak verilebilir [137].

YSA sinir sistemini taklit eden ağlar olması nedeniyle nöronların yapısı ve çalışma prensibi, yapay olarak oluşturulan nöronlara da referans olmaktadır. Nöronlar dentrit, hücre gövdesi, akson ve hücreler arası iletim elemanları olan sinapslardan oluşmaktadır. Şekil 4.1’de sinir hücresi yapısı verilmiştir.




Şekil 4.1. Sinir hücresi yapısı ve sinaps bağlantıları [138].

Yapay sinir ağı genellikle giriş katmanı, çıkış katmanı ve bir veya birden fazla gizli katmandan oluşmaktadır. Şekil 4.2’de bir yapay sinir ağı örneği verilmiştir.



Şekil 4.2. Yapay sinir ağı örneği.

Yapay bir sinir hücresi girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş temel bileşenden oluşmaktadır. Yapay sinir hücresinde toplama fonksiyonu dentritleri, transfer fonksiyonu hücre gövdesini, çıktılar aksonları, ağırlıklar sinapsları temsil etmektedir. Şekil 4.3’te yapay sinir hücresi yapısı verilmiştir.



Şekil 4.3. Yapay sinir hücresi [139].

Yapay sinir hücreleri kendisine dışardan ya da başka bir hücreden gelen girdileri ağırlıkları ile çarparak toplamlarını alır. Toplama işlemine nöronun tepki verme eşiğini belirleyen ve aktivasyon fonksiyonunun sağa sola kaydırılmasını sağlayan bias değeri eklenir. $G = \{x_1, x_2, x_3, \dots, x_n\}$ girdiler, $W = \{w_1, w_2, w_3, \dots, w_n\}$ ağırlıklar olmak üzere, Eşitlik 4.1’de toplama fonksiyonu ve nöronun çıktısı verilmiştir.

$$Net_i = \sum_{i=1}^n x_i w_i, \quad y_i = f(b_i + Net_i) \quad (4.1)$$


Aktivasyon fonksiyonu ise sinir hücresine gelen girdi verileri üzerinde işlem yaparak çıktıları oluşturur. Aktivasyon fonksiyonu çözümlenecek probleme veya kullanılacak

yönteme göre farklılık gösterebilir. Bu açıdan performansı etkileyen bir parametre olması sebebiyle doğru seçilmelidir. Eşik değer, sigmoid ve hiperbolik tanjant gibi aktivasyon fonksiyonları bulunmaktadır. Eşik değer fonksiyonu, belirlenen bir t eşik değerinden büyük olanları 1, küçük olanları 0 değerine dönüştürmektedir. Sigmoid fonksiyonu kendisine gelen veriyi $[0,1]$ aralığında bir değere dönüştürmekte ve hiperbolik tanjant fonksiyonu $[-1,1]$ aralığında bir değer üretmektedir. Eşitlik 4.2 ve 4.3'te bu fonksiyonlar sırası ile verilmiştir.

$$\text{Sigmoid} \quad f(x) = \frac{1}{1+e^{-x}} \quad (4.2)$$

$$\text{Tanh} \quad f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.3)$$

Yapay sinir ağlarında, doğrusal olmayan ve türevlenebilir yapıları sebebiyle yaygın olarak kullanılan fonksiyonlar sigmoid ve hiperbolik tanjanttır. Sigmoid ve hiperbolik tanjant fonksiyonları birbirine benzemektedir. Hiperbolik tanjant fonksiyonu orijine göre simetriktir. Ayrıca belirli bir yönde değişmeyen gradyanlara sahip olduğundan, sigmoid fonksiyonlara göre kullanımı daha çok tercih edilmektedir [140]. Şekil 4.4'te Sigmoid ve Tanh fonksiyonlarının grafik gösterimi verilmiştir.



Şekil 4.4. Sigmoid ve Tanh aktivasyon fonksiyonları.

Yapay sinir ağlarında öğrenme çıkışın, beklenen çıkış değerine yakınsamasının sağlanması şeklinde gerçekleşir. Buda sinir ağlarında eğitim ile gerçekleştirilmektedir. Sinir ağlarında eğitim ileri yayılım ve geri yayılım şeklinde iki aşamadan oluşur. İleri yayılım aşamasında sinir ağına verilen girdi verileri ileri yönlü olarak toplama ve aktivasyon fonksiyonları ileriye doğru yayılım gösterir. Ve son çıkış katmanında elde

edilen tahmin hatası hesaplanır. Geri yayılım aşaması ise ileri yayılında elde edilen tahmin hatalarına veya kayıplarına dayalı olarak bir ağın ağırlıklarına ince ayar yapılmasıdır. Geri yayılımın amacı, ağın doğruluğunu artırmak ve aynı zamanda optimizasyon tekniklerini kullanarak ağ boyunca hatayı azaltmaktır. Eşitlik 4.5'te ağırlık değiştirme formülü verilmiştir.

$$w_j^{t+1} = w_j^t + \lambda(y_i - \widehat{y}_i^t) \times x_{ij} \quad (4.5)$$

Ağırlık değişimi bir önceki ağırlığın tahmin hatasının [0,1] aralığında belirlenen bir öğrenme katsayısı ve özellik değerinin çarpımının toplanması ile bulunur. Ayrıca değiştirme işlemi her adımda beklenen değerler ile ağı hesapladığı değerler arasında oluşan hata kareleri ortalamasının minimize edilmesi ile bulunmaktadır. Kabul edilebilir bir ortalama hataya erişildiğinde eğitim sonlandırılarak son güncellenen ağırlıklar ile YSA en uygun sonucu üretmektedir [139]. Eşitlik 4.6'da hata ortalaması formülü verilmiştir.

$$E = \frac{1}{n} \sum_{i=1}^n (y_i - \widehat{y}_i^t)^2 \quad (4.6)$$

4.2. Derin Öğrenme

Yapay sinir ağlarının bir varyantı olan ve daha gelişmiş özellikler sunan derin sinir ağları son yıllarda yaygın bir şekilde makine öğrenmesi alanında kullanılmaktadır. İmaj segmentasyonu [141,142], nesne tespit etme [143], tahmin yapma [18], sınıflandırma [144–149] vb. problemlerde yaygın bir kullanım alanı bulmaktadır.

Yapay sinir ağlarına göre daha gelişmiş nöronlar içeren derin sinir ağları, derinlemesine iç içe geçmiş ağ mimari organizasyonunda birden fazla gizli katmandan oluşur. Nöronlarda basit aktivasyon fonksiyonlarını kullanmak yerine, evrişim vb. gelişmiş işlemleri veya çoklu aktivasyon fonksiyonlarını kullanır. Bu özellikler, derin sinir ağlarının ham girdi verileriyle beslenmesine ve ilgili öğrenme görevi için gerekli olan bir temsili otomatik olarak keşfetmesine olanak tanır. Bu genellikle derin öğrenme olarak bilinen ağların temel yeteneğidir [150].

Derin sinir ađları, ses, görüntü, video ve metin gibi geniş ve yüksek boyutlu verilerde geleneksel makine öğrenmesi yöntemlerine göre daha başarılı sonuçlar vermektedir [151]. Düşük boyutlu veri koşulu altında geleneksel makine öğrenmesi yöntemleri daha başarılı sonuçlar verebilmektedir [152]. Derin sinir ađlarında üzerinde çalışılan çok boyutlu veriler zaman serileri, resim verileri ve metin verileri olabilmektedir. Zaman serilerinde genellikle regresyon problemleri veya trend sınıflandırma görevleri gerçekleştirilmektedir. Resim verilerinde ise genellikle nesne tanıma, nesne sayımı ve mahsul için verim tahminlemeden araçlar için otonom sürüşe kadar geniş bir yelpazedeki görevleri yerine getirir. Metin verilerinde ise sosyal medya içeriklerinden şirket maillerine büyük boyutlu verilerin analizi görevlerini yerine getirir. Belgelerin özetlenmesi, duygu analizi ve metin tabanlı çeviri bazı örnek uygulamalarıdır [150].

Veri türleri için farklı derin sinir ađ mimarileri bulunmaktadır. Özellikle konuşma tanıma ve bilgisayar görüşü ile ilgili görevlerde kullanılan CNN bunlardan biridir. Satır ve sütunların birbirinin yerine kullanılmadığı uzaysal ilişkilere sahip resim vb. veri setlerindeki görevleri ele alabilirler. CNN ađ mimarisi, hiyerarşik özellik öğrenimine izin veren bir dizi aşamadan oluşmaktadır. Resim içerisinde basit özelliklerin (kenarlık ve köşeler vb.) elde edildiği katmanlar ile karmaşık özelliklerin çıkarıldığı (tespit edilecek nesnelerin özellikleri vb.) katmanlardan oluşmaktadır [150,153].

Dahili geri bildirim döngüleri sunan ve bununla bir bellek oluşturarak zaman bağımlılıklarını modellemek için sıralı öğrenmeyi mümkün kılan özyinelemeli sinir ađları; olay dizileri, zaman serileri ve doğal dil gibi sıralı veriler için özel olarak tanımlanmıştır. Özyinelemeli sinir ađları doğal dil işleme görevleri ve zaman serilerin tahminleme görevlerinde kullanılmaktadır [150]. Dağıtılmış temsiller, sözcükler, ifadeler ve cümleler gibi dil varlıklarının, gömme biçiminde birleştirilmiş bir anlamsal alan içinde sayısal temsillere yansıtıldığı doğal dil işleme görevlerinde özellik öğrenme ve dil modellemede önemli bir rol oynarlar [146].

Verinin daha küçük boyutlara indirildiği bir kodlama aşaması ve ađın öğrenilen özelliklerden orijinal girdiyi yeniden oluşturmaya çalıştığı bir kod çözme aşamasından

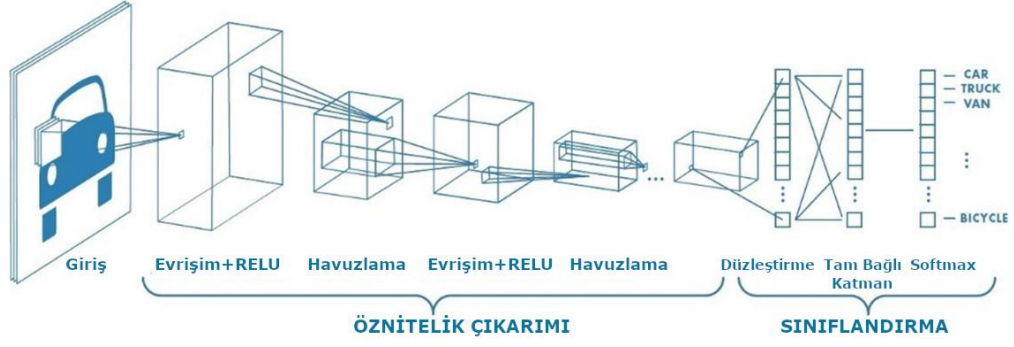
oluşan otomatik kodlayıcı ağ mimarisi bulunmaktadır. Otomatik kodlayıcı genellikle danışmansız öğrenme ve boyut indirgeme gibi amaçlarla kullanılmaktadır [153]. Üretken çekişmeli sinir ağları, ağın bazı varyasyonlarla rastgele yeni veri örnekleri oluşturabilmesi için bir dizi eğitim verisi üzerinden bir olasılık dağılımı öğrenmeyi amaçlayan bir ağ mimarisidir. Bu temelde, bu ağların sürekli olarak yeni içeriğin veya yeni ürün konfigürasyonların oluşturulduğu (örneğin, sanat ve müzik kompozisyonu, moda tasarımı) veya içeriğin bir temsilden diğerine dönüştürüldüğü (örneğin, metin) alanlarda muhtemel bir kullanım alanı bulabileceği öngörülmektedir [154].

4.2.1. Evrişimsel Sinir Ağları (CNN)

Ham veriler üzerinde sınıflandırma ve özellik çıkartımı işlemine olanak sağlayan derin sinir ağlarından olan CNN, hayvanların görme merkezlerinden esinlenerek geliştirilmiş çok katmanlı bir ileri beslemeli yapay sinir ağıdır[155]. 1980'lerde yapılan bir çalışma [156] ile ortaya çıkmasına rağmen CNN'ler 2012 yılında yapılan bir görüntü sınıflandırma çalışmasındaki [157] başarısından sonra popülerlik kazanmıştır.

CNN'ler geleneksel yapay sinir ağlarından farklı olarak orijinal veriyi giriş olarak almakta, evrişim ve havuzlama katmanları ile veriden özellik çıkarımı işlemini otomatik olarak gerçekleştirmektedir. CNN'lerde ağın derinliğini katman sayısı, ağın genişliğini de evrişim aşamasında kullanılan filtre sayısı ifade etmektedir [139].

Bir CNN ağı; giriş katmanı, özellik çıkartımı için birbirini takip eden birkaç evrişimsel (convolutional) ve havuzlama (pooling) katmanları, sınıflandırma için tam bağlantılı (fully-connected) katman ve softmax katmanından oluşmaktadır. Şekil 4.5'te bir CNN ağının genel yapısı verilmiştir.




Şekil 4.5. Bir CNN ağının genel yapısı [158].

4.2.1.1. Giriş Katmanı

CNN'nin ilk katmanı olan, ham verinin dış ortamdan alındığı ilk yer giriş katmanıdır. Giriş katmanı, tasarlanan ağ modelinin başarısı ve kaynak kullanımı açısından önemlidir. Çok boyutlu ve büyük miktarda veri üzerinde işlem yapılan derin sinir ağları için kullanılacak giriş veri boyutunun uygun seçilmesi gerekir. İşlenecek olan veri boyutu ve miktarı çok büyük seçildiğinde başarı yükselecektir. Ancak işlem gücü ve depolama gibi bilgisayar kaynaklarına gereksinim artacaktır. Veri boyutu ve miktarı küçük seçildiğinde ise kaynak kullanımı azalacaktır. Ancak model başarısı azalacaktır.

4.2.1.2. Evrişim Katmanı


Dönüşüm katmanı olarak ta bilinen evrişim katmanında, iki boyutlu görüntü verileri üzerinde $n \times n$ 'lik (1x1, 3x3, 5x5, 7x7 vb.) filtreler uygulanarak veriden çeşitli özelliklerin çıkarımı gerçekleştirilmektedir. Evrişim işlemi iki boyutlu görüntüler için iki yönlü yatay ve dikey olarak gerçekleştirilmektedir. Evrişim işleminde filtre sayısı arttıkça veriden çıkarımı yapılacak özellik sayısı artmaktadır. Ardışık katmanlarda başlangıçta büyük filtreler kullanılarak görüntünün geneli hakkında özellikler elde edilebilirken, devamında filtre boyutu küçültülerek görüntüden daha detaylı özellikler çıkarılabilmektedir [159]. Şekil 4.6'da $d=1$ kanallı görüntü evrişim işlemi örneği verilmiştir.



Şekil 4.6. $d=1$ kanallı görüntü evrişim işlemi.

$w \times h$ boyutunda 1 kanallı görüntüye uygulanan $f \times f$ boyutlu filtre sonucunda $(w-f+1) \times (h-f+1)$ boyutunda bir özellik matrisi elde edilmektedir.

2 boyutlu görüntüler için evrişim işlemi bu şekilde iken özellikle zaman serisi verileri için verilerin zaman boyutunda olması nedeniyle 1 boyutlu evrişim işlemleri gerçekleştirilmektedir. 1 boyutlu evrişim işlemleri görüntü verilerinin aksine tek yönde zaman yönünde gerçekleştirilmektedir.



Şekil 4.7. 3 boyutlu ivme ölçer verisi evrişim işlemi.

Şekil 4.7’de zaman serisi verilerinden olan ve insan hareket algılama problemlerinde kullanılan 3 boyutlu ivme ölçer verisinin evrişim işlemi verilmiştir. Evrişim boyutu 5 olan bir filtrenin 3 boyuta saniye yönünde uygulanması ile oluşmaktadır. Örneğin 128×3 olan bir ivmeölçer verisi için evrişim sonunda 124×1 ’lik bir özellik verisi elde edilmektedir [160].

4.2.1.3. Düzeltme (RELU) Katmanı


Evrişim katmanında elde edilen çıkış verisi ve bu katmana gelen giriş verisi birbiri ile doğrusaldır. Bu doğrusallığı ortadan kaldırmak için çıktıyı doyurmak veya üretilen çıktıyı sınırlamak için bu katmanda doğrusal olmayan aktivasyon fonksiyonları

kullanılmaktadır. Sigmoid ve hiperbolik tanjant fonksiyonları yaygın kullanılan doğrusal olmayan aktivasyon fonksiyonları olmasına rağmen CNN'lerde RELU ve varyantları olan aktivasyon fonksiyonları hem işlev hem de gradyan olarak daha basit tanımlamalara sahip olduğundan daha yaygın bir kullanım alanı bulmaktadır [161]. Eşitlik 4.7'de RELU aktivasyon fonksiyonu formülü verilmiştir.

$$RELU \ f(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (4.7)$$

4.2.1.4. Havuzlama (Pooling) Katmanı

Havuzlama katmanı, evrişim katmanından sonra oluşan çıktı boyutunu indirgeyerek sonraki aşamalarda evrişim katmanlarındaki işlemlerde daha az veri kullanımını, dolayısıyla verileri işlemek için gereken işlem yükünü azalmayı amaçlar. Havuzlama, modelin eğitiminde önemli olabilecek lider özelliklerin çıkarılmasında da yardımcı olmakta ve eğitim süresini azaltarak aşırı eğitimi engellemektedir [162]. Maksimum ve ortalama havuzlama bu aşamada sık kullanılan varyasyonlardır. Maksimum havuzlama, görüntüyü alt bölge dikdörtgenlerine ayırır ve yalnızca o alt bölgenin içindeki maksimum değeri döndürür. Ortalama havuzlama da ise uygulanan filtrenin dikdörtgenlere ayrıldığı bölgedeki ortalama değeri döndürür. Şekil 4.8'de 4x4 bir görüntü üzerinde 2 adım kaydırmalı maksimum havuzlama örneği verilmiştir.



Şekil 4.8. 2x2 filtre ve 2 adım kaydırma ile maksimum havuzlama [163].

4.2.1.5. Tam Bağlantılı (Fully-Connected) Katman

Tam bağlantılı katman özellik çıkarımı işleminin ardından sınıflandırma işleminin ilk katmanıdır. Evrişimsel ve havuzlama katmanlarından sonra hücrelerdeki tüm verilerin

düzeltilerek bir vektöre dönüştürülmesi gerekir. Tam bağlantılı katmanı eklemek, evrişimli katmanın çıktısıyla temsil edilen üst düzey özelliklerin doğrusal olmayan kombinasyonlarını öğrenmek için basit bir tekniktir [163].


4.2.1.6. Sınıflandırma (Softmax) Katmanı

Sınıflandırma için çıktıların belirli bir sınıfa ait olma olasılığını [0-1] aralığında değerler üreterek belirleyen katmandır. Softmax'taki nöron sayısı sınıflandırmadaki sınıf sayısı kadardır. Eşitlik 4.8'de softmax aktivasyon fonksiyonu formülü verilmiştir.

$$\sigma(Z)_i = \frac{e^{Z_i}}{\sum_{j=1}^K e^{Z_j}} \quad , j = \{1,2,3 \dots K\} \quad (4.8)$$

4.2.1.7. Seyreltme (Dropout) Katmanı

Büyük verilerle yapılan işlemlerde bazen ağ aşırı öğrenme (over-fitting) yapabilmektedir. Bu durumun önüne geçmek için tam bağlantılı katmandaki bazı düğüm ve bağlantılar göz ardı edilerek yok edilmektedir. Seyreltme oranı olarak genellikle [0,25,0,50] aralığında değerler tercih edilmektedir [164,165]. Şekil 4.9'da seyreltme yapılmış bir ağ örneği verilmiştir.



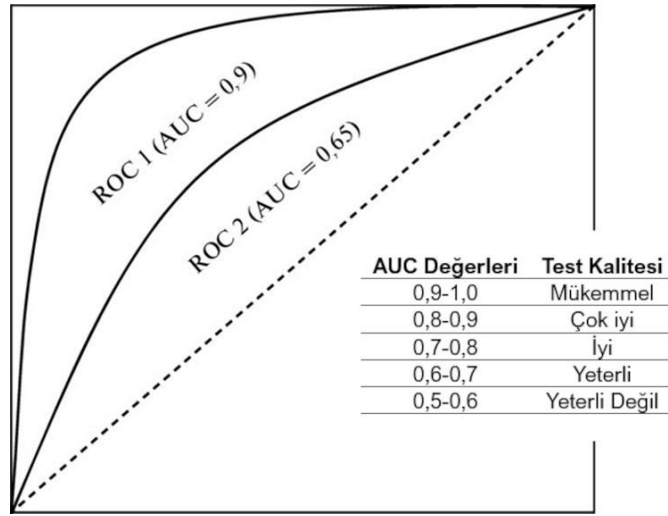
Şekil 4.9. Seyreltme yapılmış bir ağ örneği [166].

4.2.2. Sınıflandırma Performansı Ölçütleri

Performans ölçütleri, bir sınıflandırma görevinin ne derece iyi gerçekleştirildiğinin belirlenmesinde kullanılır. Makine öğrenmesi alanında birçok performans ölçütünün

varlığına rağmen bu ölçütlerin sonuçlarının birbirleri ile paralellik göstermediği durumlar gözlenebilmektedir. Hedeflenen sınıf bazlı başarıya uygun olarak çeşitli performans metrikleri kullanılabilir [167].

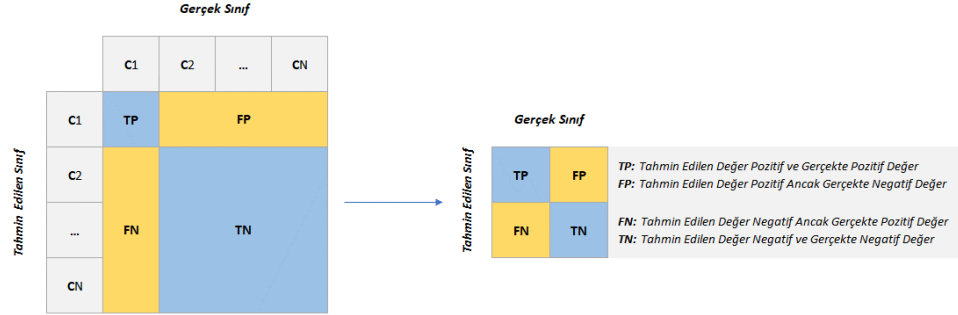
Bu çalışmada üzerinde çalışılan veri seti olan PTB-XL'nin çok etiketli yapısından dolayı performans ölçütü olarak ikili sınıflandırma kullanılmaktadır. İkili sınıflandırma problemleri için belli bir eşik (threshold) değerine göre sınıflar belirlendiği için en uygun sınıflandırma ölçütü olan eğri altındaki alan (AUC) kullanılmaktadır [114]. ROC eğrisi gerçek pozitif oranı (TPR) ve hatalı pozitif oranı (FPR) kullanılarak elde edilen ve sınıflandırma başarısı hakkında bilgi veren bir göstergedir. TPR ve FPR değerlerinin farklı eşiklerde karşılaştırmasını yapan bir eğridir. AUC değeri de bu eğrinin altında kalan alan olarak, olası tüm sınıflandırma eşiklerinde toplu bir ölçüm sağlamaktadır. AUC başarı ölçütü 1 değerine yaklaştıkça sınıflandırma duyarlılığının arttığı, 0 değerine yaklaştıkça da duyarlılığın azaldığı gözlenir. Şekil 4.10'da örnek bir ROC eğrisi verilmiştir.



Şekil 4.10. İyi (AUC = 0,9) ve tatmin edici (AUC = 0,65) özgülük ve duyarlılık parametrelerine sahip bir ROC eğrisi örneği [168].

AUC dışında sınıflandırma sonuçlarında tahmin edilen ve gerçek sınıf değerlerinin karşılaştırıldığı ve hata oranlarına gösteren doğruluk matrisi de performans ölçütü olarak kullanılmaktadır. Doğruluk matrisinden doğruluk, kesinlik, duyarlılık ve F1-

Skoru ölçütleri elde edilebilmektedir. Bu metrikler, sınıflandırmada performans ölçütü olarak kullanılmaktadır [167]. Şekil 4.11’de örnek bir doğruluk matrisi verilmiştir.



Şekil 4.11. Doğruluk matrisi.

Doğruluk ölçütü, sınıflandırma işleminde doğru tahminlenen pozitif ve negatif değerlerinin bütün tahminlere bölünmesiyle elde edilen yüzdelik bir değeri olup eşitlik 4.9’da verilmiştir.

$$Doğruluk = \frac{|TP|+|TN|}{|TP|+|FP|+|FN|+|TN|} \quad (4.9)$$

Kesinlik ölçütü sınıflandırma işleminde pozitif bir tahminin doğru olma olasılığını tahmin eden bir ölçü olup eşitlik 4.10’da verilmiştir.

$$Kesinlik = \frac{|TP|}{|TP|+|FP|} \quad (4.10)$$

Duyarlılık ölçütü sınıflandırma işleminde pozitif olarak tahmin etmemiz gereken verilerin ne kadarını pozitif olarak tahmin ettiğimizi gösteren bir ölçüttür. Eşitlik 4.11’de formülü verilmiştir.

$$Duyarlılık = \frac{|TP|}{|TP|+|FN|} \quad (4.11)$$

F1- skoru sınıflandırma işleminde kesinlik ve duyarlılık değerlerinin harmonik ortalaması ile elde edilen bir ölçüttür. F1-skoru değeri [0,1] aralığında bir değer almaktadır. F1- skoru kaç örneğin doğru sınıflandırıldığını saptayarak sınıflandırıcının

ne kadar hassas ve sağlam olduğunu gösterir. F1- skoru değerinin 1'e yakın olması modelin performansının iyi olduğu anlamına gelmektedir [169]. Eşitlik 4.12'de formülü verilmiştir.


$$F1 - Skoru = 2 * \frac{Precision*Recall}{Precision+Recall} \quad (4.12)$$

4.3. CNN Mimarileri

CNN ağ mimarileri farklı uygulamalarda yüksek performanslı sınıflandırma ve özellik çıkarımı için kritik bir öneme sahiptir. Ortaya çıktığı 1989'den günümüze yapısal değişimler, düzenlemeler ve parametrelerinin optimize edilmesi gibi değişikliklerle yeni CNN mimarileri elde edilmiştir. CNN mimarilerindeki değişimler büyük ölçüde işlem birimlerinin yeniden tanımlanması ve yeni blokların geliştirmesi ile performansta iyileştirmelere yöneliktir [170]. Görüntü tanıma ve sınıflandırmada kullanılan AlexNet [171] mimarisinin 2012 ortaya çıkmasından günümüze birçok CNN mimarisi geliştirilmiştir. Bu mimarilerden çalışmamızda kullanılan mimariler, son yıllarda çeşitli görevlerde yüksek başarımları kanıtlanmış olan ResNet ve Inception'dır. Bu bölümde bu iki modelin mimarileri hakkında bilgi verilecektir. Diğer CNN mimarileri ile ilgili detaylı bilgilere Alzubaidi vd. 2021'de yapmış oldukları çalışmadan ulaşılabilir [170].

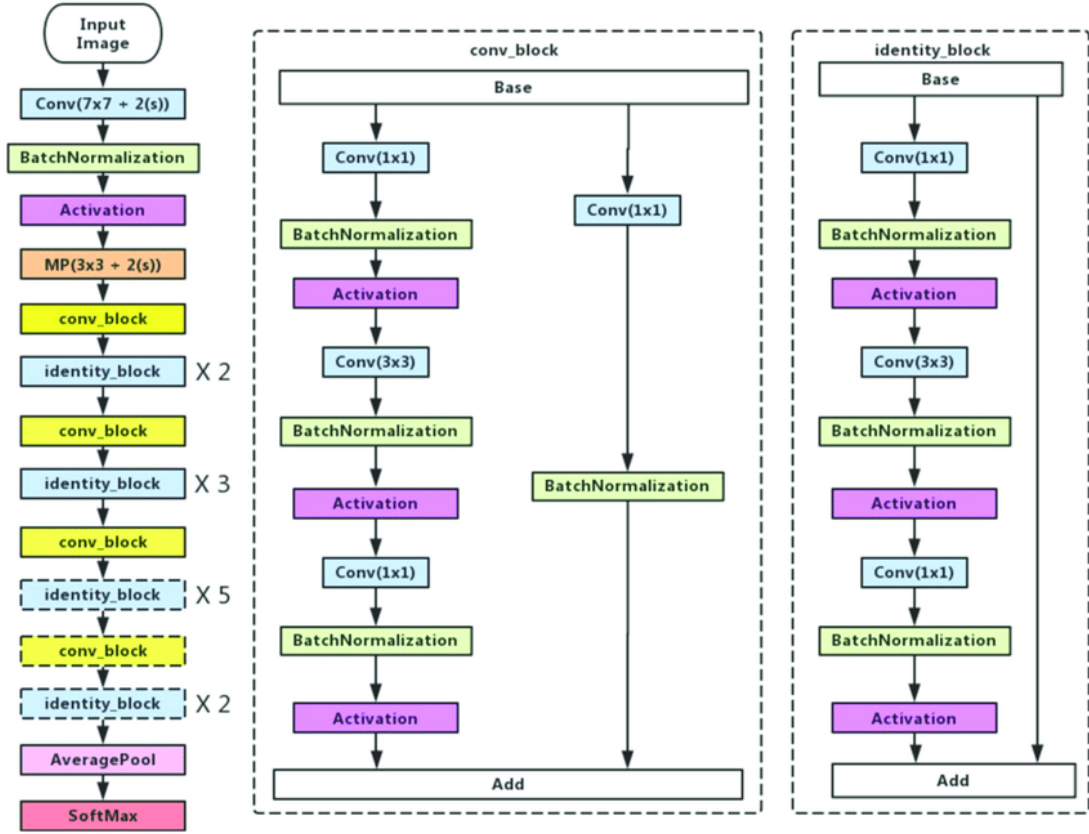
4.3.1. ResNet CNN Mimarisi

ResNet CNN mimarisi karmaşık ağların eğitimini kolaylaştırmak için geliştirilmiş bir ağ yapısıdır. Artık ağ olarak adlandırılan ve giriş verisinin diğer katman bloklarına hızlı bir şekilde yayılmasını sağlayan özelliği ile karmaşıklığı artan yapılarda performansı iyileştirmektedir [172]. Farklı katman boyutlarında birçok ResNet mimarisi geliştirilmiştir. Bunlardan en popüler olanı 49 evrimsel katmanın tam bağlantılı katmanlarla birleştirildiği ResNet50'dir. Ana fikri baypas yolu konseptine dayanan ResNet mimarisinin ileri beslemeli evrim katmanına eklenen artık bağlantılı blok diyagramı Şekil 4.12'de verilmiştir [170].



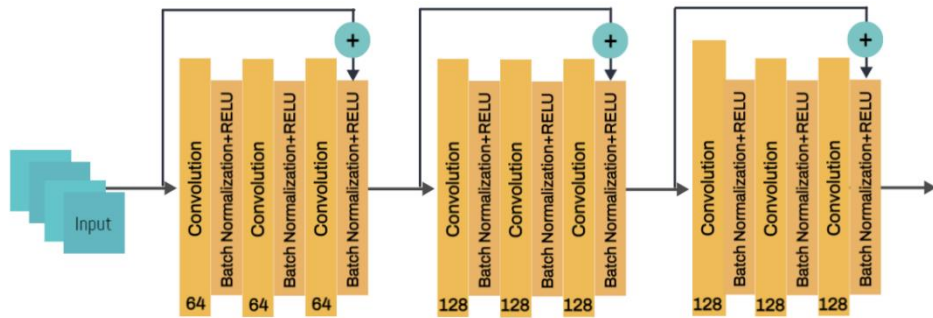
Şekil 4.12. ResNet blok diyagramı [170].

ResNet blok diyagramını incelendiğinde; herhangi bir l . katmandaki giriş verisinin blok içinde evrişim, havuzlama ve aktivasyon vb. işlemlerden geçtikten sonra giriş verisinin çıkış verisi ile birleşiminden artık çıkışlar elde edilmektedir. Artık ağlarda birçok temel artık blok içermektedir. Artık ağ mimarisinin türüne göre de artık bloktaki işlemler değişmektedir [172]. Ayrıca artık bağlantılar derin ağ yakınsamasını hızlandırdığından ResNet, gradyan azalması sorunlarını önleme potansiyeline sahiptir [170]. Popüler olarak kullanılan ResNet50 ağ mimarisi Şekil 4.13'te verilmiştir.



Şekil 4.13. ResNet50 ağ mimarisi [173].

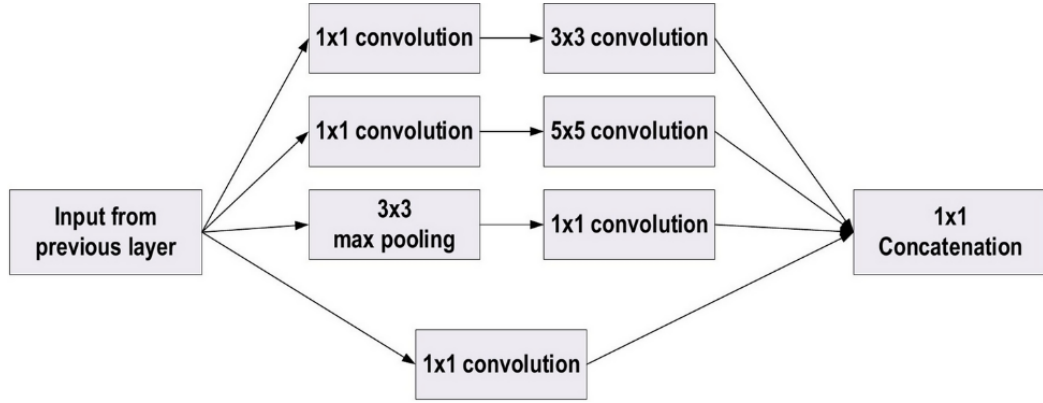
Çalışmamızda kullanılan veri seti için Wang vd. (2017) tarafından önerilen, 3 artık bloktan oluşan ve zaman serisi verilerinde başarılı sonuçlar elde edilmiş olan artık ağ modeli kullanılmıştır. Çalışmada ortaya koyulmuş olan artık ağ modelinin ilk bloğunda evrişimsel katman filtre sayısı 64, diğer kalan iki artık blokta ise filtre sayısı 128 olarak belirlenmiştir [99]. Şekil 4.14'te 3 artık bloklu CNN ağ mimarisi verilmiştir.



Şekil 4.14. ResNet1d_wang modeli [99].

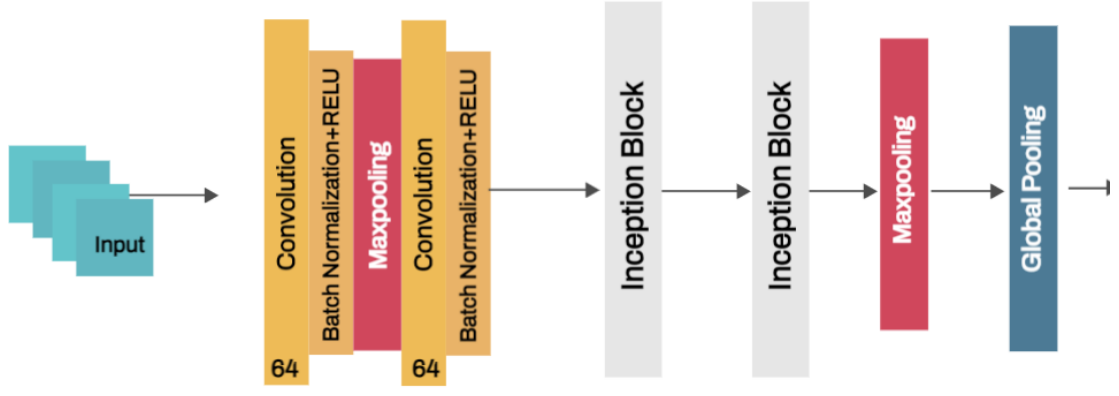
4.3.2. Inception CNN Mimarisi

Inception CNN mimarisi aynı bilgisayar kaynakları üzerinde ağın derinliğini ve genişliğini artırma yeteneğine sahiptir. Sinir ağı yapısı içerisinde değişken çekirdek yapıları kullanmaya izin vermesiyle Inception CNN mimarisi ağda hem yerel alana özgü özelliklerin çıkartılması hem de genel özelliklerin çıkartılmasında etkili bir modeldir. Alana özgü özellik çıkarmada küçük çekirdekler, ağın geneli ile ilgili özellikler çıkarmada ise büyük çekirdekler kullanılmaktadır [174]. Blok şeklindeki mimarisinde 5x5, 3x3 ve 1x1'lik filtrelerle çeşitli uzaysal çözünürlük aralıklarında uzaysal bilgilerle birlikte kanal bilgilerini yakalamaktadır. Inception blok Temel yapısı Şekil 4.15'te verilmiştir.



Şekil 4.15. Inception temel blok yapısı [170].

Inception CNN mimarisinin temel motivasyonu öğrenme kapasitesini geliştirmenin yanı sıra parametrelerin verimliliğini artırmaktır. Gereksiz bilgi sorunun önüne geçmek ve kullanılan bağlantı yoğunluğunu azaltmak için tam bağlantılı katman yerine GAP katmanını kullanmaktadır. Bu da önemli ölçüde bir parametre düşüşü sağlanmaktadır [170]. Şekil 4.16'da Örnek bir Inception CNN mimarisi verilmiştir.



Şekil 4.16. Inception CNN Mimari Örneği.

BÖLÜM 5

VERİ SETİ VE AĞ DÖNÜŞÜMÜ İLE ÖZELLİK ÇIKARIMI


Bu bölümde çalışmamızda kullanılan EKG veri seti olan PTB-XL hakkında bilgi verilmiştir. Ayrıca zaman serilerinin ağ dönüşümü ve bu ağlardan özellik çıkartımı ile ilgili kullanılan yöntemler de bu bölümde detaylanmıştır.

5.1. PTB-XL Veri Seti

EKG, kardiyolojik hastalıkların tanısında kullanılan bir araçtır. Günümüzde EKG verilerinin yorumlanması için bilgisayar tabanlı sistemler de yaygın bir kullanım alanı bulmaktadır. Bilgisayar tabanlı sistemler ile otomatik tanı ve teşhis işlemleri gerçekleştirilebilmektedir. Bu sistemlerin tasarlanması ve çalışabilir hale getirilmesi için eğitim verilerine ihtiyaç duyulmaktadır. PTB-XL verisi bu ihtiyaca dönük geliştirilmiş açık erişimli bir veri setidir [25].

PTB-XL veri seti 18869 hastaya ait 10'ar saniyelik 12 derivasyonlu EKG'yle oluşturulmuş 21801 veriden oluşmaktadır. Veri setinin orijinal örnekleme frekansı 400Hz'dir. EKG kaydı yapılan cihazın açılışı ve kapanışı sırasında ani yükselişlerden arındırmak için kesilen kayıtlar kullanılarak 500Hz üst örnekleme yapılmıştır. Ayrıca kullanım kolaylığı sağlaması açısından bir 100Hz alt örnekleme sürümü de mevcuttur. Veri setini oluşturan hastaların %52'si erkek, %48'si ise kadındır. Yaş aralıkları [0,95] arasında değişmekte, ortanca değeri 62, çeyreklikler arası değer ise 22'dir. Veri seti orijinal EKG verileri dışında *yaş* , *cinsiyet* , *boy* , *kilo* , *hemşire* , *tesis* , *cihaz ve kayıt tarihi* gibi demografik ve kayıt meta verilerini de içermektedir [25].


Kasım 1986 – Haziran 1996 tarihleri arasında kaydedilmiş EKG verilerinden oluşan veri setinde her bir kayıt için iki kardiyolog tarafından çoklu EKG durumları belirlenmiştir. Üst tanılar, alt tanılar, form ve ritim olmak üzere 71 farklı EKG durumu vardır [25]. Üst tanılar 5 farklı sınıf, alt tanılar 24 farklı sınıf içermektedir. Şekil 5.1’de Üst tanılar ve bunlara bağlı alt tanılar verilmiştir.



Şekil 5.1. PTB-XL üst tanılar ve bunlara bağlı alt tanılar [25].

Şekil 5.1’de yer alan tanı gruplarına örnek olarak; kalbin koroner arterine giden kan akışının azalması veya durması sonucu kalp kasına zarar vermesi sonucu oluşan, yaygın olarak kalp krizi olarak bilinen miyokardiyal enfarktüs (MI) [175] üst tanısı ve bunun altında yer alan bir alt tanı olan, miyokardın alt duvar bölgesine azalan perfüzyonla sonuçlanan bir koroner arter tıkanıklığından kaynaklan Alt Duvar Miyokardiyal Enfarktüsü (IMI) [176] verilebilir. İletim Bozukluğu (CD) için 9 alt tanı, Miyokardiyal Enfarktüs için 4 alt tanı, Normal EKG için 1 alt tanı, Hipertrofi (HYP) için 5 alt tanı, ST değişimi (ST/TC) için 5 alt tanı bulunmaktadır.

Tanımlar dışında EKG sinyallerini oluşturan P dalgacığı, QRS kompleksi, ST segmenti, U dalgacığı ve T dalgacıklarının durumlarını ifade eden 19 form durumu bulunmaktadır. Ayrıca EKG sinyallerinin normal sinüs, taşikardi, atriyal fibrilasyon vb. 12 ritim durumu bulunmaktadır. Şekil 5.2’de PTB-XL veri seti üst tanılarına ilişkin örnek EKG sinyal ritimleri verilmiştir.



Şekil 5.2. Örnek PTB-XL EKG sinyal ritimleri [116].

Çalışmamızda dikkate alınan EKG durumları, 5'li üst sınıf EKG tanılarıdır. Veri setinde her bir kayıt için olası tanıları çoklu etiket olarak tanımlanmıştır. Bir başka ifadeyle her bir EKG verisi, birden fazla üst sınıf EKG tanısı ile eşleşebilmektedir. Veri setinin, aynı ham dalga formlarına sahip 36 kaydın silinmiş olduğu 1.0.2 versiyonu kullanılmıştır. Sinyal verilerinden etiketleme yapılmayan kayıtları da sınıflandırma işleminde kullanılmamış, sonuç olarak toplamda 21396 kayıt ile uygulamalar gerçekleştirilmiştir.

Wagner vd. (2021) tarafından gerçekleştirilen çalışmada veri seti 10 kata bölünmüştür. Veri setinin katlara bölünmesinde tabakalı katlar yaklaşımı ile her bir sınıfa ait olan kayıt sayısı ile oransal olarak katlara dengeli dağıtılmıştır. Ayrıca veri setinin katlara dengeli dağılımında yalnızca sınıf etiketleri dikkate alınmamış yaş ve cinsiyet açısından da dengeli bir dağılım elde edilebilmesi için yaş ve cinsiyette dahil edilmiştir. Son durumda sınıf etiket değerleri, yaş ve cinsiyetin dengeli dağıldığı bir eğitim ve test verisi elde edilmiştir. 1-8 arasındaki katlar eğitim verisi olarak, 9 ve 10. katların ise veri setindeki durumlar için eşit dağılımlar göstermesi sebebiyle doğrulama ve test verisi olarak kullanılması önerilmiştir [25]. Eğitim için belirlenen katlarda 17090 kayıt, doğrulama için belirlenen 9. katta 2147 kayıt ve test için belirlenen 10. katta 2159 kayıt bulunmaktadır. Çizelge 5.1'de veri setindeki EKG tanıları ve veri sayısı verilmiştir.

Çizelge 5.1. PTB-XL üst tanı sınıfları ve kayıt sayıları.

Üst Sınıf	Bir Etiketli Kayıt	İki Etiketli Kayıt	Üç Etiketli Kayıt	Dört Etiketli Kayıt	Toplam Kayıt
Normal EKG(NORM)	9072	437	7	1	9517
Miyokardiyal Enfarktüs(MI)	2532	2083	701	157	5473
ST Değişimi(ST/TC)	2401	1880	800	156	5237
İletim Bozukluğu(CD)	1708	2478	558	157	4901
Hipertrofi(HYP)	535	1266	691	157	2649

Veri setinde kayıt sayısı en fazla olan sınıf Normal EKG'dir. En az kayıt sayısına sahip olan sınıf Hipertrofi sınıfıdır. Ayrıca EKG verilerinin doğası gereği bir kayıt birden fazla sınıfa ait olabilmektedir. Örneğin miyokardiyal enfarktüs olan kayıtlardan 2083'ü iki etiketli kayıtlar içerisinde yer almaktadır.

5.2. Ağ Dönüşümü ile Özellik Çıkarımı

Çalışmamızda EKG sınıflandırması için yapılan önemli aşamalardan biri veri setinden özellik çıkarımıdır. Özellik çıkarımı için PTB-XL veri setinde yer alan 12 derivasyonlu her bir kaydın her bir derivasyonu, ağırlıklı görünürlük ağ dönüşümü yaklaşımı ile ağ yapısına dönüştürülmüştür. Kullanılan bu yöntem ile EKG sinyallerinde yer alan pozitif ve negatif trendlerin tanımlanmış olduğu ağırlıklar, oluşturulan ağa düğümler arası ağırlık olarak dahil edilmektedir. Bununla birlikte elde edilen her bir ağın bağlantılarını tanımlayan komşuluk matrisi ve düğümlere ait dereceler özellik çıkarımı için kullanılmıştır.

5.2.1. Komşuluk Matrisi Köşegenleri Kullanılarak Özellik Çıkarımı

Komşuluk matrisi, ağ içerisindeki düğümler ve aralarındaki bağlantı bilgilerinin tutulduğu ve ağ hakkındaki tüm bilgileri taşıyan önemli bir yapıdır. EKG verilerinde zaman içerisinde yer alan ardışık komşu veri noktalarının dizilimi, kardiyolojik rahatsızlıkların belirlenmesi ve sinyallerin yorumlanması açısından önem taşır. Ağırlıklı görünürlük ağ dönüşümü yaklaşımı ile bu veri noktaları arasındaki ilişkiler negatif ve pozitif değerli ağırlıklar ile ifade edilmektedir. Sonuç olarak ağırlıklı bir komşuluk matrisi elde edilmektedir.

N sayıda düğüme sahip bir ağın komşuluk matrisi $A=(a_{ij})$ olmak üzere, v_i ve v_j ağda bulunan iki nokta ve $w_{i,j}$ bağlantı ağırlığı olmak üzere her bir bağlantı eşitlik 5.1'de yer alan formül ile hesaplanmaktadır.

$$a_{ij} = \{ w_{i,j}, \text{ eğer } v_i \text{ ve } v_j \text{ bağlantılı ise, değilse } 0 \} \quad (5.1)$$

Komşuluk matrisinin oluşturulması ile matriste yer alan her bir satır bir düğüme ait tüm bağlantıların bilgisini, ana köşegen ise 0 olan öz bağlantı değerlerini tutmaktadır.

Düğümün zaman eksenindeki en yakın komşularına olan bağlantıları, ağırlık değerleri ile ana köşegenin bir üst paralelindeki köşegende (1. köşegen) tutulmaktadır. 10'ar saniyelik 100Hz'lik verilerin kullanıldığı PTB-XL veri setinde her bir derivasyonda yer alan veri noktası sayısı 1000'dir. Uygulanan ağırlıklı görünürlük ağ dönüşümü sonucunda 1000x1000 boyutunda bir komşuluk matrisi elde edilmektedir. Her bir kayıt EKG verisi için yapılan bu dönüşüm, 1000x1000x12 boyutlu bir özellik temsili anlamına gelmektedir. Bu temsilin yüksek boyutluluğundan ötürü matrisin n adet köşegeni (komşuluk), özellik seti olarak kullanılmıştır. Bu şekilde veri boyutunu indirgeyerek sınıflandırma işlemi yapılması amaçlanmıştır. Ayrıca ardışık bağlantılı olabilecek veri noktalarının özellik setinde yer almasının da sınıflandırmaya EKG verisi özelinde katkı sağlayacağı düşünülmüştür.

Şekil 5.3'te örnek bir ağ dönüşümü sonucunda oluşan komşuluk matrisinden çıkarılan özellik seti verilmiştir. En yakın komşuların bulunduğu hücrelerden oluşan 1. köşegen sarı olarak işaretlenmiş, ikinci dereceli komşuların bulunduğu 2. köşegen açık mavi renkte işaretlenmiş, üçüncü dereceli komşulukların bulunduğu 3. köşegen ise yeşil renkte işaretlenmiştir.

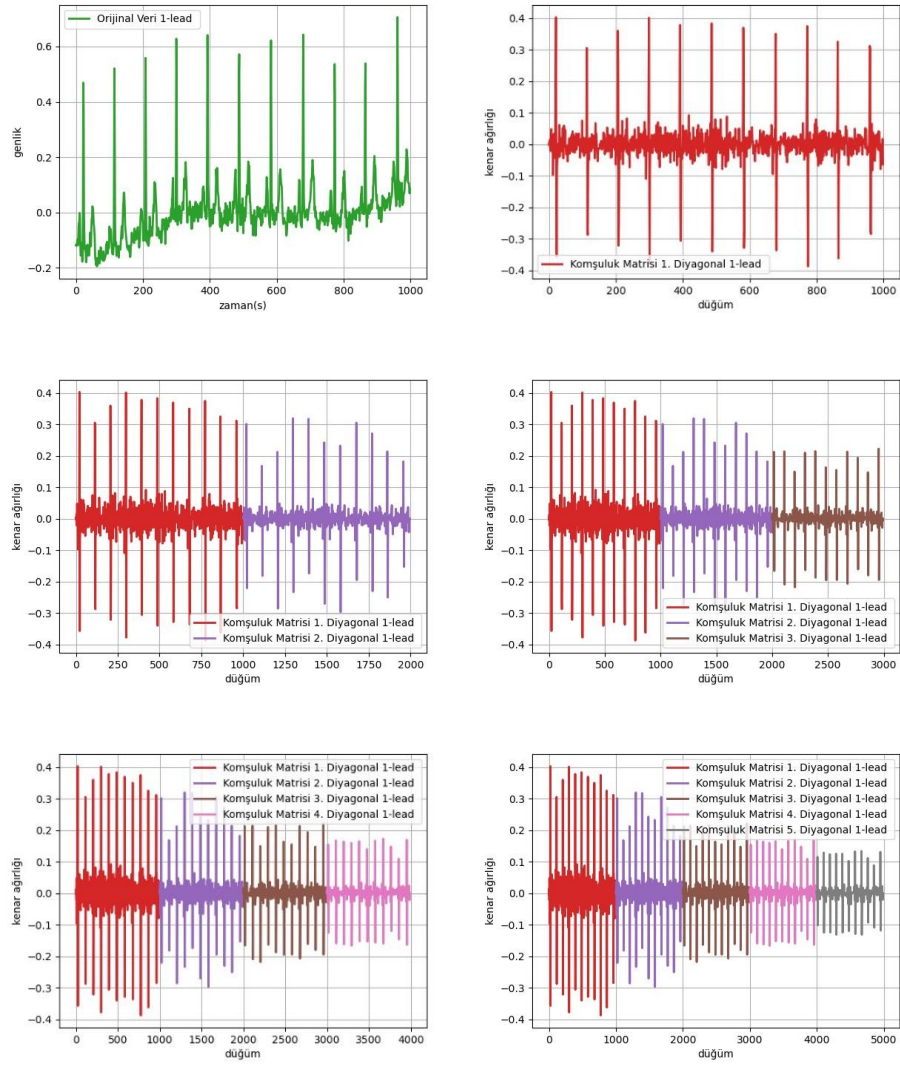


Şekil 5.3. Özellik seti olarak kullanılan bir komşuluk matrisinden çıkarılan ilk n köşegen.

1000 noktadan oluşan bir derivasyon kayıt verisi için ilk n köşegenin alınması ile oluşan veri sayısı:

- 1 köşegen en yakın komşuları içerir. 999 veri noktası olan bir dizi döndürür.
- 2 köşegen en yakın ve ikinci derece komşuları içerir. 999, 998 olmak üzere toplamda 1997 veri noktası içeren iki dizi döndürür.
- 3 köşegen en yakın, ikinci ve üçüncü derece komşuları içerir. 999, 998, 997 olmak üzere toplamda 2994 veri noktası içeren üç dizi döndürür.
- 4 köşegen en yakın, ikinci, üçüncü ve dördüncü derece komşuları içerir. 999, 998, 997, 996 olmak üzere toplamda 3990 veri noktası içeren dört dizi döndürür.
- 5 köşegen en yakın, ikinci, üçüncü, dördüncü ve beşinci derece komşuları içerir. 999, 998, 997, 996 ve 995 olmak üzere toplamda 4995 veri noktası içeren beş dizi döndürür.

Çalışmamızda n köşegen sayısı parametresi için 1-5 aralığında denemeler yapılmıştır. 5'ten büyük olan değerleri ise, veri boyutunu artırması ve sınıflandırma başarısında düşüşe neden olması sebebiyle uygulanmamıştır.



Şekil 5.4. PTB-XL orijinal veri ve n köşegen dönüşümleri sonucunda elde edilen özellik seti grafikleri.

Şekil 5.4'te 1 derivasyonlu orijinal veri grafiği ve n köşegen dönüşümleri sonucunda oluşan özellik setinin grafiği verilmiştir. Burada köşegen sayısı arttıkça düğümlerin komşularından uzaklaşılması etkisi ile bağlantı ağırlık değerlerinde düşüşler oluşmaktadır. 1 köşegen komşuluk ağırlıkları en yakın komşu olması nedeniyle en büyük değerleri alırken 5 köşegen komşuluklarının hepsinin gösterildiği son grafikte düğüm ekseninde 3990-4985 düğümleri arası komşuluk ağırlıkları en düşük değerleri almaktadır.

5.2.2. Ağırlıklı Düğüm Dereceleri ile Özellik Çıkarımı

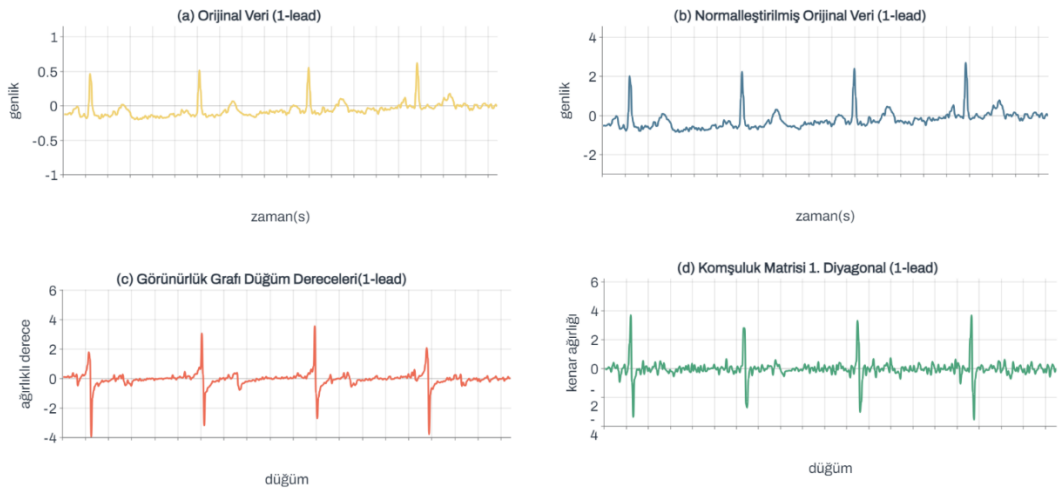
Özellik çıkarımı için kullanılan bir diğer yöntem, elde edilen ağı oluştururan düğümlerin diğer düğümlerle bağlantı sayısını ifade eden düğüm derece değerlerinin kullanılmasıdır. Düğümlere ait dereceler, ilgili düğüme ait bağlantı ağırlıklarının toplanması ile elde edilmektedir. Dolayısıyla ağ yapısı içerisindeki bir düğümün bağlantılı olduğu diğer düğümlerle olan ilişkileri, bu düğümlerin zaman ekseninde birbirine olan uzaklığından bağımsız olarak bu özellik setine doğrudan etki etmektedir.

EKG veri setini oluşturan her bir derivasyona ait düğüm derece verileri, ilgili derivasyona ait ağırlıklandırılmış görünülük ağ dönüşümü ile elde edilen 1000 düğümlü bir ağı oluşturan her bir düğümün ağırlıklı derecelerinden oluşmaktadır. $A=(a_{ij})$ ağırlıklı ağ komşuluk matrisi, v_i ağda bulunan bir düğüm, m ilgili v_i noktasının komşularının sayısı ve $deg(v_i)$ düğümün derecesi olmak üzere eşitlik 5.2’de derece formülü verilmiştir. Sonuç olarak 12 derivasyonlu EKG verisi, 1000x12’lik bir derece özellik setine dönüşmektedir.

$$deg(v_i) = \sum_{j=1}^m a_{ij}, \quad \begin{bmatrix} deg(v_1) \\ deg(v_2) \\ deg(v_3) \\ deg(v_4) \\ deg(v_5) \\ deg(v_6) \\ deg(v_7) \\ deg(v_8) \\ deg(v_9) \\ deg(v_{10}) \end{bmatrix} \rightarrow \begin{bmatrix} -0,643 \\ 0,100 \\ 1,107 \\ 0,463 \\ -1,048 \\ -0,321 \\ 0,702 \\ -1,249 \\ -2,214 \\ -1,107 \end{bmatrix} \quad (5.2)$$

Sınıflandırma denemelerinde orijinal veri dışında sınıflandırma performansını iyileştireceği düşünülen, aritmetik ortalaması 0 ve standart sapması 1 olan z-skor standardizasyon işlemi uygulanarak ölçeklendirilen ham veriden elde edilen bir özellik seti de sınıflandırma denemelerine dahil edilmiştir. Eğitim verisi katları birleştirilerek bir global ortalama ve standart sapma hesaplanmış, bütün verilerin normalizasyon işleminde bu global değerler kullanılmıştır.

İki Farklı yöntem sonucunda çıkartılan özellik setlerine ait grafikler (a) orijinal sinyal veri grafiği, (b) Orijinal verinin standartlaştırılması sonucu oluşan yeni veri, (c) Görünürlük ağı sonucunda sıra ile ağda düğümlerin ağırlıklı derecelerini gösteren veri grafiği, (d) Komşuluk matrisindeki 1. Köşegen verilerini gösteren grafik olmak üzere Şekil 5.5'te verilmiştir. Grafikler incelendiğinde ağ dönüşümü sonucu elde edilen derece ve komşuluk matrisi tabanlı özelliklerin, zaman serisi veri noktaları arasındaki pozitif ve negatif yönlü trendleri büyük ölçüde yansıttığı gözlenmektedir. Aynı zamanda zaman uzayından düğüm uzayına bir dönüşüm gerçekleşmektedir.



Şekil 5.5. Dönüşümler sonucu elde edilen yeni özellik verileri (1-derivasyon).

BÖLÜM 6

SINIFLANDIRMA UYGULAMASI

Özellik çıkartımı işleminin ardından gerçekleştirilen aşama EKG verilerinin derin öğrenme ağları ile sınıflandırılmasıdır. Bu bölümde, elde edilen özellik setleri için kullanılan ResNet ve Inception sınıflandırıcı modelleri ve parametreleri verilmiştir. Ayrıca özellik setlerinin kombinasyonlarından oluşan farklı giriş verileri ile EKG sınıflandırması yapılmış ve sonuçları verilmiştir.

6.1. Sınıflandırıcı Modeller

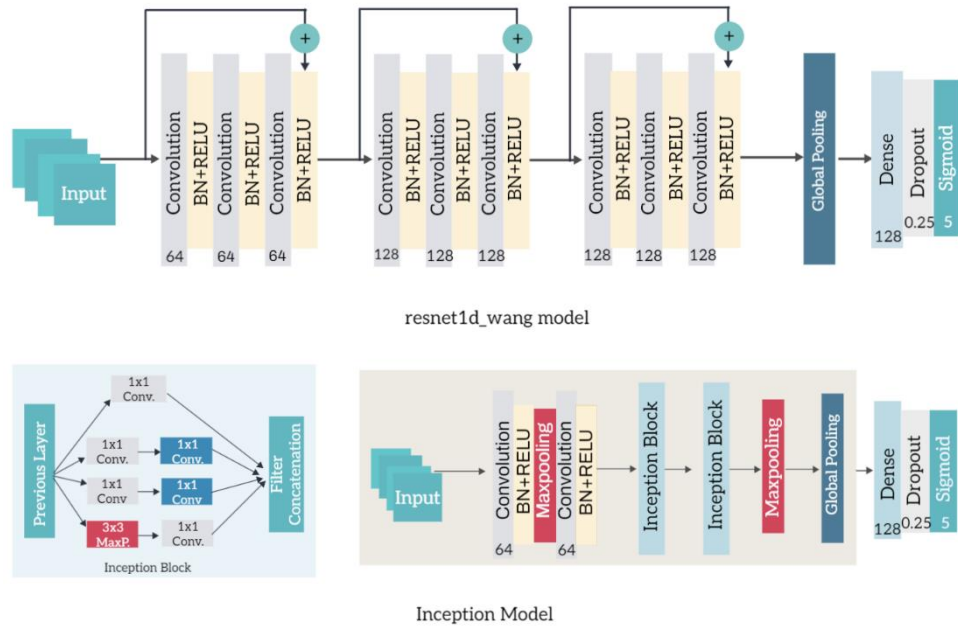
Literatürde PTB-XL veri seti ile gerçekleştirilen ve farklı sinir ağı yapılarının kullanıldığı çeşitli sınıflandırma çalışmaları mevcuttur. Strodthoff vd.'nin bu veri seti için farklı derin ağ yapılarını kullandığı çalışması [32], Smigiel vd.'nin EKG sinyallerinin sınıflandırmasını derin öğrenme tekniklerini kullanarak gerçekleştirdiği çalışması [112] ve Sharma ve Eskicioğlu'nun EKG sınıflandırmada evrimsel sinir ağlarını kullandığı çalışması [111] bunlara örnek olarak verilebilir.

Literatürde yer alan çeşitli sınıflandırma çalışmalarında kullanılan farklı derin öğrenme yöntemleri arasında görece başarılı olan modeller, bu tez çalışmasında sınıflandırma aşaması için tercih edilmiştir. Strodthoff vd. 2021'de yapmış oldukları çalışmada üst sınıf sınıflandırmasındaki en başarılı yöntem ResNet ağıdır. Çalışmamızda ilk tercih edilen model bu ağıdır. Wang vd., 2017'de yapmış oldukları çalışmada zaman serisi verileri için sınıflandırmada bu modelin başarılı sonuçlar verdiğini göstermişlerdir [99]. Bu çalışmada kullanılmış olan ResNet ağ modeline tez çalışmamızda da yer verilmiştir. Model, 3 artık bloktan oluşmakta ilk blokta evrimsel katman filtre sayısı 64 diğer kalan iki artık blokta filtre sayısı 128 olarak belirlenmiştir.

ResNet modeli dışında kullanılan bir diğer derin öğrenme ağ modeli de Inception'dır. Sinir ağ yapısı içerisinde değişken çekirdek yapıları kullanmaya izin veren Inception modeli, ağda hem yerel alana özgü özelliklerin çıkartılması hem de genel özelliklerin çıkartılmasında etkili bir modeldir. Alana özgü özellik çıkarmada küçük çekirdekler, ağın geneli ile ilgili özellikler çıkarmada ise büyük çekirdekler kullanılmaktadır [174]. Inception modeli Strodthoff vd.'nin 2021'de yapmış olduğu çalışmasında alt sınıf sınıflandırmasında en başarılı olan yöntem olarak dikkat çekmekte olup, özellik çıkarımı yapmış olduğumuz veriler üzerinde de bu başarıyı gösterebileceği değerlendirildiğinden, tez çalışmamızda tercih edilen bir diğer ağ modeli olmuştur.

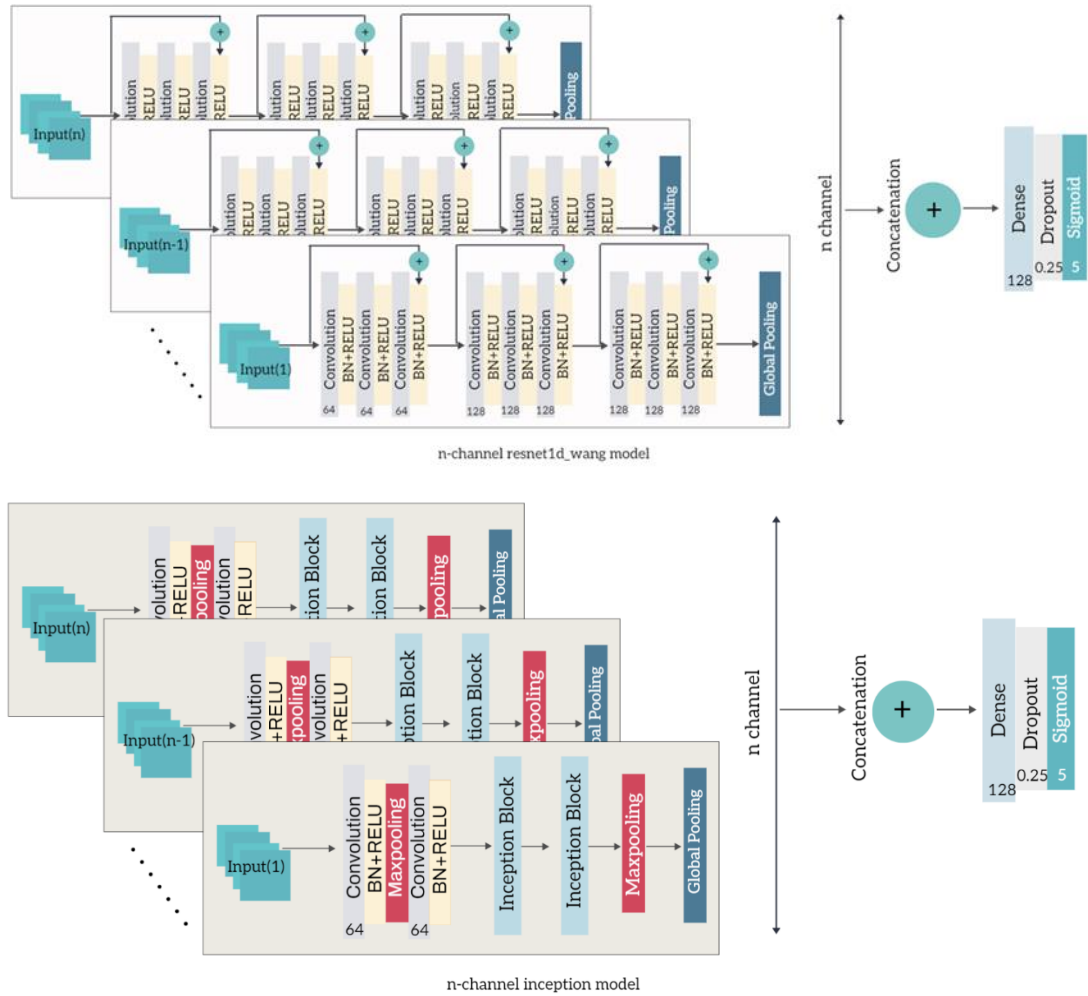
Özellik veri setlerinin boyutlarının uyumluluğunu sağlamak için 1-boyutlu evrişimler hem ResNet hem de Inception modelinde kullanılmıştır. 1-boyutlu evrişimler sinyal işleme alanında ardışık örneklerde dalgalanmalardaki özellikleri keşfetmede yetenekli bir çözüm sunmaktadır. 1-boyutlu evrişimler kullanılarak oluşturulan ağ modelleri tekrarlayan katmanlara sahip olan RNN ve LSTM'ye kıyasla daha hızlı ve düşük maliyetle çalışmaktadır [116].

Giriş verisi olarak seçilen özellik setleri için 1-kanallı ve n-kanallı sinir ağ modelleri kullanılmıştır. 1-kanallı ağ modeli Şekil 6.1'de verilmiştir.



Şekil 6.1. Sınıflandırmada kullanılan ResNet ve Inception modelleri [177].

N-kanallı modeller Şekil 6.2.'de verilmiştir. N-kanallı modeller komşuluk matrisinden elde edilen 2 ve daha fazla (N) diyagonal verisi için kullanılmıştır. Ayrıca orijinal verinin, komşuluk matrisinden elde edilen ilk diyagonal verisi ve düğüm ağırlıklarıyla birlikte giriş verisi olarak kullanılmıştır. N-kanallı modelde her bir kanalda gerçekleşen evrişim işlemlerinin ardından elde edilen özellikler, düzleştirme katmanından önce birleştirilmektedir.



Şekil 6.2. N-Kanallı ResNet ve Inception modelleri [177].

Kullanılan ağ modellerinde sınıflandırma aşamasında 128 birime sahip düzleştirme katmanı, 0,25 oranına sahip seyreltme katmanı ve sigmoid aktivasyon fonksiyonuna sahip çıkış katmanı kullanılmıştır. Bu parametreler Strodtthoff vd. 2021'de yapmış oldukları çalışmadan referans alınarak, kıyaslanabilirliği artırmak için seçilmiştir [32].

Ağ modelleri için giriş verisi boyutları, uygulanan özellik setlerine göre değişkenlik göstermektedir. Her bir özellik seti seçimi için aşağıdaki giriş verisi boyutları ile çalışılmıştır:

- *Orijinal Veri*: 1000x12 (1000 veri noktası ve 12 derivasyon).
- *Düğüm Ağırlıkları*: 1000x12 (1000 düğüm ve 12 derivasyon)
- *Komşuluk Matrisi Diyagonaller*: (Şekil 6.2.'de gösterildiği gibi her blok ayrı bir evrişim kanalında paralel olarak işlenir):
 - *İlk Diyagonal*: [999x12]
 - *İlk 2 Diyagonal*: [999x12] ve [998x12]
 - *İlk 3 Diyagonal*: [999x12], [998x12] ve [997x12]
 - *İlk 4 Diyagonal*: [999x12], [998x12], [997x12] ve [996x12]
 - *İlk 5 Diyagonal*: [999x12], [998x12], [997x12], [996x12] ve [995x12]
- *Orijinal Veri ve Komşuluk Matrisinin İlk Diyagonalı*: [1000x12] ve [999x12] (Şekil 6.2.'de gösterildiği gibi her blok ayrı bir evrişim kanalında paralel olarak işlenir)
- *Orijinal Veri ve Düğüm Ağırlıkları*: [1000x12] ve [1000x12] (Şekil 6.2.'de gösterildiği gibi her blok ayrı bir evrişim kanalında paralel olarak işlenir)

6.2. Sınıflandırma Denemeleri ve Sonuçları

Özellik veri setleri ResNet ve Inception ağ modellerinde 10 kez tekrarlanan sınıflandırma işlemine tabi tutulmuştur. Sınıflandırmada doğruluk, F1-Skoru ve AUC metriklerinin ortalama ve maksimum başarımları elde edilmiştir. Ağların eğitimi için Adam optimize edici kullanılmış ve öğrenme oranı olarak 0,001 değeri belirlenerek değişken öğrenme oranı ile doğrulama değer değişimlerine bağlı olarak $lr = lr \times 0,2$ olarak belirlenmiştir. Maksimum iterasyon sayısı da denemelerde 50 olarak belirlenmiştir. Ayrıca aşırı öğrenmeyi engellemek için de erken durdurma özelliği kullanılmış ve doğrulama AUC değeri değişimleriyle kontrol edilmiştir.

Sınıflandırma denemeleri veri boyutunun yüksek hacimli olması ve hız faktöründen dolayı Google Colab Pro platformunda gerçekleştirilmiştir.

6.2.1. Orijinal Veri ile Sınıflandırma

Sınıflandırma denemelerinde ilk olarak kullanılan derin öğrenme modellerinin orijinal veri üzerindeki performansı incelenmiştir. Bu yolla, sınıflandırıcı modellerin öncelikle hiçbir ağ dönüşümü yapılmamış ham veri üzerindeki başarısının ölçülmesi amaçlanmıştır. Ölçülecek başarımlar, aynı öğrenme modelleri ile gerçekleştirilecek ağ dönüşümlü öğrenme çalışmaları için de bir referans noktası teşkil edecektir.

Çizelge 6.1. Orijinal veri ile gerçekleştirilen ResNet modeli sınıflandırma sonuçları.

Deneme No	ResNet Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,8845	0,7696	0,9288	0,8855	0,7679	0,9242
2	0,8861	0,774	0,9312	0,8904	0,7802	0,9277
3	0,8844	0,7707	0,9308	0,889	0,7785	0,9272
4	0,8851	0,7726	0,9304	0,8905	0,7814	0,9281
5	0,8848	0,7701	0,9303	0,8886	0,7765	0,9264
6	0,8855	0,7714	0,9301	0,8875	0,7743	0,9261
7	0,8832	0,7667	0,9293	0,8876	0,7745	0,9265
8	0,8827	0,7661	0,9303	0,8865	0,7711	0,9253
9	0,8841	0,7708	0,9303	0,8884	0,776	0,926
10	0,884	0,7686	0,9298	0,8863	0,7712	0,9254
Ortalama	0,8844	0,7701	0,9301	0,888	0,7752	0,9263
SS	0,001	0,0023	0,0007	0,0016	0,0041	0,0011
En Düşük	0,8827	0,7661	0,9288	0,8855	0,7679	0,9242
En Yüksek	0,8861	0,774	0,9312	0,8905	0,7814	0,9281

Çizelge 6.1’de görüldüğü gibi, ResNet modelinde test verileri ile gerçekleştirilen sınıflandırmada başarı ölçütü olarak kullanılan AUC değeri en yüksek %92,81, en düşük %92,42 ve ortalama %92,63 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,11 olarak hesaplanmıştır. Ayrıca bir diğer başarı ölçütü olarak kullanılan F1-Skoru değeri en yüksek %78,14, en düşük %76,79 ve ortalama %77,52

olarak ölçülmüş ve tüm denemeler için standart sapması $\mp\%0,41$ olarak hesaplanmıştır.

Çizelge 6.2. Orijinal veri ile gerçekleştirilen Inception modeli sınıflandırma sonuçları.

Deneme No	Inception Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,885	0,7708	0,9276	0,8842	0,7681	0,9233
2	0,8836	0,7702	0,9226	0,8834	0,7677	0,922
3	0,8831	0,7665	0,9199	0,8811	0,7612	0,9164
4	0,8835	0,7668	0,9239	0,8828	0,7649	0,92
5	0,8827	0,7658	0,9216	0,882	0,7643	0,9183
6	0,8885	0,7776	0,926	0,8842	0,7686	0,9213
7	0,889	0,7783	0,9247	0,8855	0,7711	0,9218
8	0,8839	0,772	0,9254	0,8813	0,7602	0,9208
9	0,8813	0,7616	0,9234	0,8826	0,7624	0,9206
10	0,8855	0,7704	0,9234	0,8847	0,7695	0,922
Ortalama	0,8846	0,77	0,9239	0,8832	0,7658	0,9207
SS	0,0023	0,0049	0,0021	0,0014	0,0035	0,0019
En Düşük	0,8813	0,7616	0,9199	0,8811	0,7602	0,9164
En Yüksek	0,889	0,7783	0,9276	0,8855	0,7711	0,9233

Çizelge 6.2’de görüldüğü gibi, Inception modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek $\%92,33$, en düşük $\%91,64$ ve ortalama $\%92,07$ olarak ölçülmüş ve tüm denemeler için standart sapma değeri $\mp\%0,19$ olarak hesaplanmıştır. Ayrıca F1-Skoru değeri en yüksek $\%77,11$, en düşük $\%76,02$ ve ortalama $\%76,58$ olarak ölçülmüş ve tüm denemeler için standart sapması $\mp\%0,35$ olarak hesaplanmıştır.

6.2.2. Standartlaştırılmış Orijinal Veri ile Sınıflandırma

Orijinal veriye alternatif olarak z-skor standardizasyonuna tabi tutularak oluşturulan veri seti ile bu işlemin ne ölçüde başarımı etkilediğini belirleyen bir sınıflandırma denemesi gerçekleştirilmiştir.

Çizelge 6.3. Standartlaştırılmış veri ile gerçekleştirilen ResNet modeli sınıflandırma sonuçları.

Deneme No	ResNet Modeli			Test		
	Doğrulama Doğruluk	F1-Skoru	AUC	Doğrulama Doğruluk	F1-Skoru	AUC
1	0,8869	0,7731	0,9331	0,8899	0,7792	0,9275
2	0,8847	0,7714	0,9328	0,8911	0,7835	0,9302
3	0,8848	0,7716	0,9314	0,891	0,7838	0,9295
4	0,888	0,7772	0,9332	0,8884	0,777	0,9284
5	0,889	0,7788	0,9332	0,8908	0,7814	0,9292
6	0,8846	0,7703	0,9316	0,8867	0,7744	0,9291
7	0,8872	0,7774	0,9339	0,8872	0,7765	0,929
8	0,8861	0,7786	0,9315	0,8878	0,7797	0,9297
9	0,8861	0,775	0,9294	0,8877	0,777	0,9274
10	0,8874	0,7751	0,9323	0,8869	0,7726	0,9281
Ortalama	0,8865	0,7749	0,9322	0,8888	0,7785	0,9288
SS	0,0014	0,003	0,0012	0,0017	0,0035	0,0009
En Düşük	0,8846	0,7703	0,9294	0,8867	0,7726	0,9274
En Yüksek	0,889	0,7788	0,9339	0,8911	0,7838	0,9302

Çizelge 6.3'te görüldüğü gibi, ResNet modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %93,02, en düşük %92,74 ve ortalama %92,88 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,09 olarak hesaplanmıştır. Öte yandan F1-Skoru değeri en yüksek %78,38, en düşük %77,26 ve ortalama %77,85 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,35 olarak hesaplanmıştır.

Çizelge 6.4. Standartlaştırılmış veri ile gerçekleştirilen Inception modeli sınıflandırma sonuçları.

Deneme No	Inception Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,8857	0,776	0,9285	0,8883	0,778	0,9262
2	0,8843	0,769	0,9287	0,8884	0,7753	0,927
3	0,8853	0,776	0,9301	0,8865	0,7761	0,9273
4	0,8866	0,7743	0,9295	0,8873	0,774	0,9258
5	0,8878	0,7758	0,9313	0,8873	0,7738	0,9284
6	0,8861	0,7745	0,9301	0,8869	0,7748	0,925
7	0,885	0,7697	0,9269	0,8839	0,7676	0,9245
8	0,8864	0,7743	0,9282	0,8881	0,7756	0,9261
9	0,8857	0,7737	0,9309	0,8872	0,7749	0,9269
10	0,8862	0,776	0,9301	0,8899	0,781	0,9274
Ortalama	0,8859	0,7739	0,9294	0,8874	0,7751	0,9265
SS	0,0009	0,0024	0,0013	0,0015	0,0032	0,0011
En Düşük	0,8843	0,769	0,9269	0,8839	0,7676	0,9245
En Yüksek	0,8878	0,776	0,9313	0,8899	0,781	0,9284

Çizelge 6.4'te görüldüğü gibi, Inception modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %92,84, en düşük %92,45 ve ortalama %92,65 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,11 olarak hesaplanmıştır. Ayrıca F1-Skoru değeri en yüksek %78,1, en düşük %76,76 ve ortalama %77,51 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,32 olarak hesaplanmıştır.

6.2.3. Düğüm Ağırlıklı Derece Verileri ile Sınıflandırma

Bir diğer sınıflandırma, ağırlıklı görünürlük graf dönüşümü ile oluşan ağa ait her bir düğümün ağırlıklı dereceleri ile oluşturulan özellik veri setinin kullanıldığı denemedir. Bu deneme ile veri noktalarının uzak ve yakın ayırt edilmeksizin birbirleri ile olan bağlantı ilişkilerinin sınıflandırmaya olan etkileri incelenmiştir.

Çizelge 6.5. Düğüm ağırlıklı derece verileri ile gerçekleştirilen ResNet modeli sınıflandırma sonuçları.

Deneme No	ResNet Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,8851	0,772	0,9294	0,8865	0,7751	0,9291
2	0,8816	0,7667	0,9305	0,8836	0,7707	0,9258
3	0,8877	0,776	0,9313	0,8887	0,7787	0,9276
4	0,8871	0,7747	0,9312	0,8875	0,7752	0,9265
5	0,8891	0,7791	0,9321	0,889	0,7786	0,9287
6	0,8881	0,7774	0,9315	0,8887	0,7788	0,9268
7	0,8856	0,7731	0,9303	0,8868	0,775	0,9264
8	0,8872	0,7737	0,9313	0,8878	0,7759	0,9265
9	0,8871	0,7762	0,9325	0,8873	0,7757	0,9264
10	0,885	0,7709	0,9316	0,8855	0,773	0,9271
Ortalama	0,8864	0,774	0,9312	0,8871	0,7757	0,9271
SS	0,002	0,0034	0,0009	0,0016	0,0025	0,001
En Düşük	0,8816	0,7667	0,9294	0,8836	0,7707	0,9258
En Yüksek	0,8891	0,7791	0,9325	0,889	0,7788	0,9291

Çizelge 6.5'te görüldüğü gibi, ResNet modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %92,91, en düşük %92,58 ve ortalama %92,71 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,1 olarak hesaplanmıştır. F1-Skoru değeri ise en yüksek %77,18, en düşük %77,07 ve ortalama %77,57 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,25 olarak hesaplanmıştır.

Çizelge 6.6. Düzüm ağırlıklı derece verileri ile gerçekleştirilen Inception modeli sınıflandırma sonuçları.

Deneme No	Inception Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,8852	0,7709	0,9284	0,8862	0,7722	0,9231
2	0,8836	0,7698	0,9294	0,888	0,7781	0,9254
3	0,8853	0,7701	0,9292	0,888	0,7758	0,9238
4	0,8876	0,7767	0,9293	0,89	0,7811	0,9271
5	0,8853	0,7735	0,9303	0,8865	0,7754	0,9243
6	0,8844	0,768	0,9296	0,8857	0,7693	0,9228
7	0,8857	0,7716	0,9272	0,8853	0,7715	0,923
8	0,8869	0,7756	0,9273	0,8875	0,7765	0,9236
9	0,8864	0,7733	0,9276	0,8862	0,7729	0,922
10	0,885	0,7704	0,9282	0,8827	0,766	0,9229
Ortalama	0,8855	0,772	0,9287	0,8866	0,7739	0,9238
SS	0,0011	0,0026	0,001	0,0019	0,0042	0,0014
En Düşük	0,8836	0,768	0,9272	0,8827	0,766	0,922
En Yüksek	0,8876	0,7767	0,9303	0,89	0,7811	0,9271

Çizelge 6.6’da görüldüğü gibi, Inception modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %92,71, en düşük %92,2 ve ortalama %92,38 olarak ölçülmüş ve tüm denemeler için standart sapma değeri $\mp\%0,14$ olarak hesaplanmıştır. Ayrıca F1-Skoru değeri en yüksek %78,11% en düşük %76,6 ve ortalama %77,39 olarak ölçülmüş ve tüm denemeler için standart sapması $\mp\%0,42$ olarak hesaplanmıştır.

6.2.4. Ağırlıklı Komşuluk Matrisi Diyagonalleri ile Sınıflandırma

EKG verisinin ağırlıklı görünürlük ağırları ile dönüşümü sonucunda elde edilen ağırlık düğüm ve bağlantılarını gösteren komşuluk matrisinin ana diyagonaline en yakın komşulukta bulunan ilk 1-5 arası diyagonaller özellik vektörleri olarak kullanılmıştır. Bu deney grubunda, Inception modeli ResNet modeli kadar başarılı sonuçlar vermediği

için bu model çift sayıdaki diyagonallerde kullanılmayarak sadece tek sayıdaki diyagonallerden oluşan özellik vektörleri ile çalıştırılmıştır.

6.2.4.1. İlk Diyagonal Verisi ile Sınıflandırma

İlk diyagonal verisi ile gerçekleştirilen sınıflandırma denemesinde tek kanallı ResNet ve Inception modelleri kullanılmıştır.

Çizelge 6.7. İlk diyagonalden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.

Deneme No	ResNet Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,89	0,7809	0,9334	0,89	0,7804	0,9302
2	0,8901	0,7817	0,9345	0,8905	0,7814	0,9305
3	0,8868	0,774	0,9328	0,8879	0,7763	0,9296
4	0,8894	0,7806	0,9345	0,8924	0,7862	0,9323
5	0,8893	0,7812	0,9359	0,8929	0,7887	0,9301
6	0,8892	0,779	0,932	0,8905	0,7826	0,9285
7	0,8874	0,7764	0,9317	0,891	0,7831	0,9308
8	0,8824	0,7667	0,9303	0,8902	0,7802	0,9279
9	0,8905	0,7834	0,9332	0,8918	0,7848	0,9312
10	0,8865	0,7747	0,9335	0,8916	0,7833	0,9311
Ortalama	0,8882	0,7779	0,9332	0,8909	0,7827	0,9302
SS	0,0023	0,0048	0,0015	0,0013	0,0033	0,0012
En Düşük	0,8824	0,7667	0,9303	0,8879	0,7763	0,9279
En Yüksek	0,8905	0,7834	0,9359	0,8929	0,7887	0,9323

Çizelge 6.7’de görüldüğü gibi, ResNet modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %93,23, en düşük %92,79 ve ortalama %93,02 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,12 olarak hesaplanmıştır. Ayrıca F1-Skoru değeri en yüksek %78,87, en düşük %77,63 ve

ortalama %78,27 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,33 olarak hesaplanmıştır.

Çizelge 6.8. İlk diyagonalden oluşan özellik seti ile Inception modeli sınıflandırma sonuçları.

Deneme No	Inception Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,8839	0,7723	0,93	0,8888	0,7795	0,9274
2	0,8878	0,7752	0,9331	0,8887	0,775	0,9277
3	0,8877	0,7766	0,9333	0,8908	0,7834	0,9294
4	0,8874	0,7766	0,9312	0,8893	0,7802	0,9289
5	0,8861	0,775	0,9321	0,8897	0,783	0,929
6	0,8861	0,7729	0,9309	0,8914	0,7833	0,9287
7	0,8862	0,7761	0,9341	0,8921	0,7871	0,9296
8	0,885	0,7719	0,9309	0,8915	0,7841	0,9289
9	0,8861	0,7746	0,9301	0,8909	0,783	0,9289
10	0,8857	0,7746	0,9308	0,89	0,7822	0,9295
Ortalama	0,8862	0,7746	0,9317	0,8903	0,7821	0,9288
SS	0,0012	0,0016	0,0013	0,0011	0,0031	0,0007
En Düşük	0,8839	0,7719	0,93	0,8887	0,775	0,9274
En Yüksek	0,8878	0,7766	0,9341	0,8921	0,7871	0,9296

Çizelge 6.8’de görüldüğü gibi, Inception modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %92,96, en düşük %92,74% ve ortalama %92,88 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,07% olarak hesaplanmıştır. F1-Skoru değeri ise en yüksek %78,71, en düşük %77,5 ve ortalama %78,21 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,31 olarak hesaplanmıştır.

6.2.4.2. İlk 2 Diyagonal Verisi ile Sınıflandırma

İlk 2 diyagonal verisi ile gerçekleştirilen sınıflandırma denemesinde 2 kanallı ResNet ağ modeli kullanılmıştır.

Çizelge 6.9 İlk 2 diyagonalden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.

Deneme No	ResNet Modeli			Test		
	Doğrulama			Doğrulama		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,889	0,7796	0,9354	0,8942	0,7892	0,9316
2	0,8884	0,7776	0,9358	0,8908	0,7835	0,9312
3	0,8865	0,7749	0,9344	0,889	0,7792	0,9289
4	0,8902	0,7792	0,9336	0,8904	0,7796	0,9291
5	0,8882	0,7766	0,9342	0,8898	0,779	0,9312
6	0,8871	0,776	0,9341	0,8901	0,7817	0,9282
7	0,8893	0,782	0,9348	0,8971	0,7961	0,9332
8	0,8878	0,777	0,9332	0,8906	0,7819	0,9308
9	0,8876	0,7763	0,9363	0,8934	0,7866	0,9316
10	0,8913	0,7826	0,9336	0,8922	0,7846	0,9318
Ortalama	0,8885	0,7782	0,9345	0,8918	0,7841	0,9308
SS	0,0014	0,0025	0,001	0,0024	0,0051	0,0015
En Düşük	0,8865	0,7749	0,9332	0,889	0,779	0,9282
En Yüksek	0,8913	0,7826	0,9363	0,8971	0,7961	0,9332

Çizelge 6.9’da görüldüğü gibi, ResNet modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %93,32, en düşük %92,82 ve ortalama %93,08 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,15 olarak hesaplanmıştır. Ayrıca F1-Skoru değeri en yüksek %79,61, en düşük %78,41 ve ortalama %77,9 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,51 olarak hesaplanmıştır.

6.2.4.3. İlk 3 Diyagonal Verisi ile Sınıflandırma

İlk 3 diyagonal verisi ile gerçekleştirilen sınıflandırma denemesinde üç kanallı ResNet ve Inception Ağ modelleri kullanılmıştır.

Çizelge 6.10. İlk 3 diyagonalden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.

Deneme No	ResNet Modeli			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,887	0,7745	0,9359	0,8927	0,7863	0,9337
2	0,8876	0,7765	0,9345	0,8919	0,7856	0,9322
3	0,8898	0,7806	0,9351	0,8937	0,788	0,9324
4	0,8857	0,7755	0,934	0,8885	0,7805	0,9284
5	0,8878	0,7746	0,9342	0,8912	0,7848	0,9311
6	0,8878	0,7774	0,9326	0,8927	0,7867	0,9322
7	0,8861	0,775	0,9331	0,8941	0,7886	0,9336
8	0,8888	0,78	0,9347	0,8923	0,7859	0,9346
9	0,8898	0,781	0,9345	0,892	0,7842	0,9303
10	0,8883	0,7783	0,9355	0,8944	0,7909	0,9323
Ortalama	0,8879	0,7773	0,9344	0,8924	0,7862	0,9321
SS	0,0013	0,0024	0,001	0,0016	0,0027	0,0017
En Düşük	0,8857	0,7745	0,9326	0,8885	0,7805	0,9284
En Yüksek	0,8898	0,781	0,9359	0,8944	0,7909	0,9346

Çizelge 6.10’da görüldüğü gibi, ResNet modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %93,46, en düşük %92,84 ve ortalama %93,21 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,17% olarak hesaplanmıştır. Öte yandan F1-Skoru değeri en yüksek %79,09, en düşük %78,05 ve ortalama %78,62% olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,27 olarak hesaplanmıştır.

Çizelge 6.11. İlk 3 diyagonalden oluşan özellik seti ile Inception modeli sınıflandırma sonuçları.

Deneme No	Inception Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,8864	0,7722	0,9313	0,8902	0,7774	0,9295
2	0,8873	0,7747	0,9332	0,891	0,7818	0,9281
3	0,8867	0,7746	0,9322	0,8889	0,7782	0,9285
4	0,8861	0,774	0,932	0,8889	0,782	0,9292
5	0,8823	0,7649	0,9304	0,8905	0,783	0,9297
6	0,8857	0,7734	0,9306	0,8904	0,7814	0,9282
7	0,8859	0,7733	0,9335	0,8904	0,7827	0,9302
8	0,8889	0,7811	0,9316	0,8937	0,7903	0,9316
9	0,8856	0,7712	0,9293	0,8885	0,7782	0,9288
10	0,8863	0,7759	0,9286	0,8899	0,7815	0,9282
Ortalama	0,8861	0,7735	0,9313	0,8902	0,7817	0,9292
SS	0,0016	0,0038	0,0015	0,0014	0,0035	0,001
En Düşük	0,8823	0,7649	0,9286	0,8885	0,7774	0,9281
En Yüksek	0,8889	0,7811	0,9335	0,8937	0,7903	0,9316

Çizelge 6.11’de görüldüğü gibi, Inception modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %93,16, en düşük %92,81 ve ortalama %92,92 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,1 olarak hesaplanmıştır. F1-Skoru değeri ise en yüksek %79,03, en düşük %77,74 ve ortalama %78,17 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,35 olarak hesaplanmıştır.

6.2.4.4. İlk 4 Diyagonal Verisi ile Sınıflandırma

İlk 4 diyagonal verisi ile gerçekleştirilen sınıflandırma denemesinde 4 kanallı ResNet ağ modeli kullanılmıştır.

Çizelge 6.12. İlk 4 diyagonalden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.

Deneme No	ResNet Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,8867	0,7737	0,9343	0,8908	0,782	0,929
2	0,8877	0,7778	0,9354	0,8899	0,7823	0,9311
3	0,8881	0,7749	0,9345	0,8893	0,7758	0,9312
4	0,8877	0,7753	0,9354	0,89	0,7778	0,9311
5	0,8895	0,7785	0,9349	0,891	0,7821	0,9321
6	0,8869	0,7753	0,9334	0,8916	0,7831	0,93
7	0,8873	0,7785	0,9349	0,8901	0,7835	0,9311
8	0,8889	0,7816	0,9344	0,8911	0,7861	0,9315
9	0,8876	0,7775	0,9345	0,8893	0,7803	0,9311
10	0,8893	0,7786	0,9348	0,8947	0,7891	0,9339
Ortalama	0,888	0,7772	0,9347	0,8908	0,7822	0,9312
SS	0,0009	0,0022	0,0006	0,0015	0,0036	0,0012
En Düşük	0,8867	0,7737	0,9334	0,8893	0,7758	0,929
En Yüksek	0,8895	0,7816	0,9354	0,8947	0,7891	0,9339

Çizelge 6.12’de görüldüğü gibi, ResNet modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %93,39, en düşük %92,9 ve ortalama %93,12 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,12 olarak hesaplanmıştır. Ayrıca F1-Skoru değeri en yüksek %78,91, en düşük %77,58 ve ortalama %78,22 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,36 olarak hesaplanmıştır.

6.2.4.5. İlk 5 Diyagonal Verisi ile Sınıflandırma

İlk 5 diyagonal verisi ile gerçekleştirilen sınıflandırma denemesinde üç kanallı ResNet ve Inception modelleri kullanılmıştır.

Çizelge 6.13. İlk 5 diyagonalden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.

Deneme No	ResNet Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,889	0,7794	0,9347	0,8923	0,7855	0,9294
2	0,8871	0,7754	0,9347	0,8932	0,7875	0,9312
3	0,8878	0,7777	0,9342	0,8925	0,7876	0,9317
4	0,8888	0,7783	0,9337	0,8912	0,7821	0,9305
5	0,8882	0,7791	0,9346	0,8911	0,7838	0,931
6	0,8854	0,7745	0,9335	0,8952	0,7928	0,9328
7	0,8837	0,7672	0,9321	0,8923	0,7856	0,9309
8	0,8868	0,7739	0,9347	0,8906	0,7813	0,931
9	0,8875	0,777	0,9339	0,8903	0,7815	0,9304
10	0,8878	0,7762	0,9346	0,892	0,7855	0,9308
Ortalama	0,8872	0,7759	0,9341	0,8921	0,7853	0,931
SS	0,0015	0,0034	0,0008	0,0014	0,0033	0,0008
En Düşük	0,8837	0,7672	0,9321	0,8903	0,7813	0,9294
En Yüksek	0,889	0,7794	0,9347	0,8952	0,7928	0,9328

Çizelge 6.13'te görüldüğü gibi, ResNet modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %93,28, en düşük %92,94 ve ortalama %93,10 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,08 olarak hesaplanmıştır. F1-Skoru değeri ise en yüksek %79,28, en düşük %78,13 ve ortalama %78,53 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,33 olarak hesaplanmıştır.

Çizelge 6.14. İlk 5 diyagonalden oluşan özellik seti ile Inception modeli sınıflandırma sonuçları.

Deneme No	Inception Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,8836	0,7692	0,9302	0,8872	0,7759	0,928
2	0,886	0,7739	0,9307	0,892	0,7857	0,93
3	0,8831	0,7686	0,929	0,8891	0,7809	0,927
4	0,8864	0,774	0,931	0,8919	0,7858	0,9282
5	0,8851	0,773	0,9324	0,8933	0,7885	0,9308
6	0,8866	0,7746	0,9317	0,8912	0,7838	0,9291
7	0,8828	0,766	0,9306	0,8883	0,7779	0,927
8	0,8837	0,7685	0,9309	0,8899	0,7808	0,9304
9	0,8828	0,7695	0,9302	0,889	0,7802	0,9295
10	0,8845	0,7712	0,93	0,892	0,7869	0,9312
Ortalama	0,8845	0,7709	0,9307	0,8904	0,7826	0,9291
SS	0,0014	0,0028	0,0009	0,0019	0,0039	0,0014
En Düşük	0,8828	0,766	0,929	0,8872	0,7759	0,927
En Yüksek	0,8866	0,7746	0,9324	0,8933	0,7885	0,9312

Çizelge 6.14'te görüldüğü gibi, Inception modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %93,12, en düşük %92,7 ve ortalama %92,91 olarak ölçülmüş ve tüm denemeler için standart sapma değeri $\mp\%0,1$ olarak hesaplanmıştır. Ayrıca F1-Skoru değeri en yüksek %78,85, en düşük %77,59 ve ortalama %78,26 olarak ölçülmüş ve tüm denemeler için standart sapması $\mp\%0,39$ olarak hesaplanmıştır.

6.2.5. Orijinal Veri ile Komşuluk Matrisi ilk Diyagonalı kullanılarak Sınıflandırma

Bir diğer sınıflandırma deney seti ise orijinal veri ve ilk diyagonal verilerinin birlikte 2 kanallı ResNet ve Inception ağ modellerine girdi olarak verilmesidir. Bu iki farklı

öznitelik setinin birlikte kullanımı ile sınıflandırma başarısına etkisi ölçülmüş ve sonuçları verilmiştir.

Çizelge 6.15. Orijinal veri ile komşuluk matrisi ilk diyagonalinin birleşiminden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.

Deneme No	ResNet Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,8894	0,7814	0,9352	0,8927	0,787	0,9317
2	0,8881	0,7787	0,9355	0,8921	0,7858	0,9316
3	0,8888	0,7781	0,9337	0,8933	0,7882	0,9303
4	0,8881	0,7783	0,9349	0,8928	0,787	0,9315
5	0,8892	0,7852	0,9361	0,8897	0,7815	0,9327
6	0,8866	0,7749	0,9344	0,8924	0,7862	0,9324
7	0,8882	0,7784	0,9338	0,8929	0,7859	0,9321
8	0,8889	0,7776	0,936	0,891	0,7815	0,9316
9	0,8893	0,7802	0,9352	0,8903	0,7824	0,9311
10	0,8898	0,7826	0,9355	0,8922	0,7876	0,9324
Ortalama	0,8886	0,7795	0,935	0,8919	0,7853	0,9317
SS	0,0009	0,0028	0,0008	0,0011	0,0024	0,0007
En Düşük	0,8866	0,7749	0,9337	0,8897	0,7815	0,9303
En Yüksek	0,8898	0,7852	0,9361	0,8933	0,7882	0,9327

Çizelge 6.15'te görüldüğü gibi, ResNet modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %93,27, en düşük %93,03 ve ortalama %93,17 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,07 olarak hesaplanmıştır. Ayrıca F1-Skoru değeri en yüksek %78,82, en düşük %78,15 ve ortalama %78,53 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,24 olarak hesaplanmıştır.

Çizelge 6.16. Orijinal veri ile komşuluk matrisi ilk diyagonalinin birleşiminden oluşan özellik seti ile Inception modeli sınıflandırma sonuçları.

Deneme No	Inception Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,8845	0,7689	0,9305	0,89	0,7798	0,9282
2	0,8837	0,768	0,9299	0,8871	0,7746	0,9276
3	0,8881	0,7779	0,9322	0,8909	0,7823	0,9288
4	0,8852	0,7737	0,9306	0,89	0,7825	0,9284
5	0,8876	0,777	0,9316	0,8914	0,7837	0,9304
6	0,8874	0,7778	0,9319	0,8911	0,7838	0,9299
7	0,8865	0,7736	0,9314	0,8908	0,782	0,9301
8	0,8862	0,7736	0,9317	0,8908	0,7828	0,9297
9	0,8872	0,7746	0,9314	0,8907	0,7817	0,9289
10	0,8847	0,7741	0,9309	0,8905	0,7812	0,9291
Ortalama	0,8861	0,7739	0,9312	0,8903	0,7814	0,9291
SS	0,0014	0,0032	0,0007	0,0012	0,0025	0,0009
En Düşük	0,8837	0,768	0,9299	0,8871	0,7746	0,9276
En Yüksek	0,8881	0,7779	0,9322	0,8914	0,7838	0,9304

Çizelge 6.16’da görüldüğü gibi, Inception modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %93,04 en düşük %92,91 ve ortalama %92,76 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,09 olarak hesaplanmıştır. Ayrıca F1-Skoru değeri en yüksek %78,38, en düşük %77,46 ve ortalama %78,14 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,25 olarak hesaplanmıştır.

6.2.6. Orijinal Veri ile Düğüm Ağırlıklı Dereceleri ile Sınıflandırma

Bu deney setinde orijinal veri ve düğüm ağırlıklı derece verileri birlikte 2 kanallı ResNet ve Inception ağ modellerine girdi olarak verilmiştir. Bu iki farklı öznetelik setinin birlikte kullanımı ile sınıflandırma başarısına etkisi ölçülmüş ve sonuçları verilmiştir.

Çizelge 6.17. Orijinal veri ile ağırlıklı düğüm derecelerinin birleşiminden oluşan özellik seti ile ResNet modeli sınıflandırma sonuçları.

Deneme No	ResNet Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,885	0,7704	0,9308	0,8899	0,78	0,9291
2	0,8891	0,7822	0,9321	0,8869	0,7779	0,9281
3	0,8864	0,7743	0,9316	0,8904	0,7815	0,9294
4	0,889	0,7791	0,9316	0,891	0,7826	0,9266
5	0,8866	0,776	0,9318	0,8885	0,7792	0,9282
6	0,8875	0,7766	0,9324	0,8901	0,7816	0,9285
7	0,8863	0,7719	0,9309	0,8885	0,776	0,9287
8	0,8869	0,7766	0,9333	0,8929	0,7884	0,9298
9	0,8848	0,7698	0,9318	0,8872	0,7742	0,9284
10	0,8849	0,7705	0,9322	0,887	0,7749	0,9288
Ortalama	0,8867	0,7747	0,9319	0,8892	0,7796	0,9286
SS	0,0015	0,0039	0,0007	0,0019	0,004	0,0008
En Düşük	0,8848	0,7698	0,9308	0,8869	0,7742	0,9266
En Yüksek	0,8891	0,7822	0,9333	0,8929	0,7884	0,9298

Çizelge 6.17’de görüldüğü gibi, ResNet modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %92,98, en düşük %92,66 ve ortalama %92,86 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,08 olarak hesaplanmıştır. F1-Skoru değeri ise en yüksek %78,84, en düşük %77,42 ve ortalama %77,96 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,4 olarak hesaplanmıştır.

Çizelge 6.18. Orijinal veri ile ağırlıklı düğüm derecelerinin birleşiminden oluşan özellik seti ile Inception modeli sınıflandırma sonuçları.

Deneme No	Inception Modeli					
	Doğrulama			Test		
	Doğruluk	F1-Skoru	AUC	Doğruluk	F1-Skoru	AUC
1	0,8845	0,7694	0,9269	0,8855	0,772	0,9269
2	0,8854	0,7736	0,9284	0,8865	0,7789	0,9267
3	0,8875	0,7774	0,9329	0,8886	0,7795	0,9279
4	0,8846	0,7693	0,9306	0,8888	0,7786	0,9264
5	0,8855	0,7684	0,9288	0,8864	0,7703	0,9258
6	0,8861	0,7742	0,9302	0,888	0,7766	0,9277
7	0,8871	0,776	0,9321	0,8907	0,7826	0,9274
8	0,8887	0,7783	0,9316	0,8892	0,7791	0,9289
9	0,8878	0,7756	0,9314	0,8865	0,7733	0,9263
10	0,8847	0,7722	0,9325	0,8902	0,7832	0,9278
Ortalama	0,8862	0,7734	0,9305	0,888	0,7774	0,9272
SS	0,0014	0,0033	0,0019	0,0017	0,0041	0,0009
En Düşük	0,8845	0,7684	0,9269	0,8855	0,7703	0,9258
En Yüksek	0,8887	0,7783	0,9329	0,8907	0,7832	0,9289

Çizelge 6.18’de görüldüğü gibi, Inception modelinde test verileri ile gerçekleştirilen sınıflandırmada AUC değeri en yüksek %92,89, en düşük %92,58 ve ortalama %92,72 olarak ölçülmüş ve tüm denemeler için standart sapma değeri \mp %0,09 olarak hesaplanmıştır. Ayrıca F1-Skoru değeri en yüksek %78,32, en düşük %77,03 ve ortalama %77,74 olarak ölçülmüş ve tüm denemeler için standart sapması \mp %0,41 olarak hesaplanmıştır.

6.3. Özellik Çıkartımı ve Sınıflandırma Uygulamasının Çalışma Zaman Bilgileri

Gerçekleştirilen tez çalışmasında sınıflandırma aşamasından önce özellik çıkartımı metotları kullanılmaktadır. Özellik çıkartımı işlemi için ekstra bir çalışma zamanı ve bellek alanı ihtiyacı ortaya çıkmaktadır. Özellik çıkartımı için ağırlıklı görünürlük graf dönüşümü yaklaşımı kullanılmıştır. Lan vd. 2015’te yapmış oldukları çalışmada

görünürlük graf dönüşümü algoritmasını $O(n^2)$ zaman karmaşıklığından böl-fethet yöntemini uyguladığı algoritma ile iyileştirme sağlayarak zaman karmaşıklığını $O(n \log n)$ 'e yükseltmiştir [62]. Ayrıca zaman serisi üzerinde görünürlük graf dönüşümleri için gerekli olan alan karmaşıklığı $O(n^2)$ 'dir [178]. Tez çalışmasında da kullanılan bu yöntem ile özellik çıkartımı için geçerli olan zaman karmaşıklığı tek bir EKG kaydı için bu şekildedir. PTB-XL veri setinde yer alan bütün kayıtları için zaman karmaşıklığı $O(n m k \log k)$ 'dir. Notasyondaki n elemanı veri setindeki toplam kayıt sayısı, m elemanı derivasyon sayısı ve k elemanı her bir EKG derivasyonundaki veri noktası sayısıdır.

PTB-XL veri setindeki yer alan her bir kayıt için Google Colab Pro platformunda özellik çıkartımı ~0,6sn sürede gerçekleşme ve aynı platformda tüm veriler için ~213,97dk sürmektedir.

Sınıflandırma aşamasında deneme sayısının fazlalığı sebebiyle yalnızca orijinal veri ile en iyi sınıflandırma performansının olduğu ilk 3 köşegenin ResNet sınıflandırıcısı ile yapılan denemeler için eğitim ve test aşaması çalışma süreleri hesaplanmıştır. 10 kez tekrar eden denemeler, orijinal veri için eğitim aşaması ortalama 15,1dk sürmekte ve test verisi sınıflandırması ortalama 2sn sürmekte; ilk 3 köşegen özelliği için eğitim aşaması ortalama 24,97dk sürmekte ve test verisi sınıflandırma ortalaması 4sn sürmektedir. Eğitim ve Test aşaması için 16GB DDR6 hafızaya sahip NVIDIA TESLA T4 GPU kullanılmıştır.

Sınıflandırma denemelerine ait sonuçların analizi ve değerlendirilmesi bir sonraki bölümde gerçekleştirilmiştir.

BÖLÜM 7

SONUÇLARIN ANALİZİ VE ÖNERİLER

Farklı özellik setleri ile gerçekleştirilen sınıflandırma deney setleri sonuçları dikkate alındığında komşuluk matrisinin köşegenlerinin kullanıldığı yöntemde, ilk 3 köşegenin ResNet sınıflandırıcı ile en iyi sonucu verdiği görülmektedir. Bu koşullar altında AUC değeri olarak maksimum %93,46 ve ortalama %93,21 ile en iyi sınıflandırma başarımları elde edilmiştir. ResNet sınıflandırıcı, bu özellik seti için orijinal verilere göre AUC için %0,58, F1-Skoru için %1,09 ve doğruluk metrikleri için %0,68 iyileştirme sağlarken, normalize edilmiş orijinal veriye göre sırasıyla %0,33, %0,76 ve %0,36 iyileştirme sağlamıştır.

Aynı deneysel kurulum ile Inception sınıflandırıcıda da orijinal veri ile gerçekleştirilen sınıflandırmaya göre AUC için %0,27, F1-Skoru için %0,65 ve doğruluk metrikleri için %0,29 iyileştirme sağlanmıştır. Ancak Inception modeli, ResNet modelindeki başarıya ulaşamamıştır. Bununla birlikte ilk 3 komşuluk köşegeni kullanımının ResNet ve Inception sınıflandırıcıları için en iyi sonuçları verdiği gözlenmiştir.

Düğüm ağırlıklı derece değerlerinin kullanıldığı ikinci yaklaşım ise orijinal veri ile gerçekleştirilen sınıflandırmaya göre çok daha sınırlı düzeyde iyileştirme sunmaktadır. Ancak normalleştirilmiş orijinal verilere göre sınıflandırma başarısı düşüktür. O yüzden orijinal verilere kıyasla bu özellik setinin iyileştirme sağlayamadığı söylenebilir.

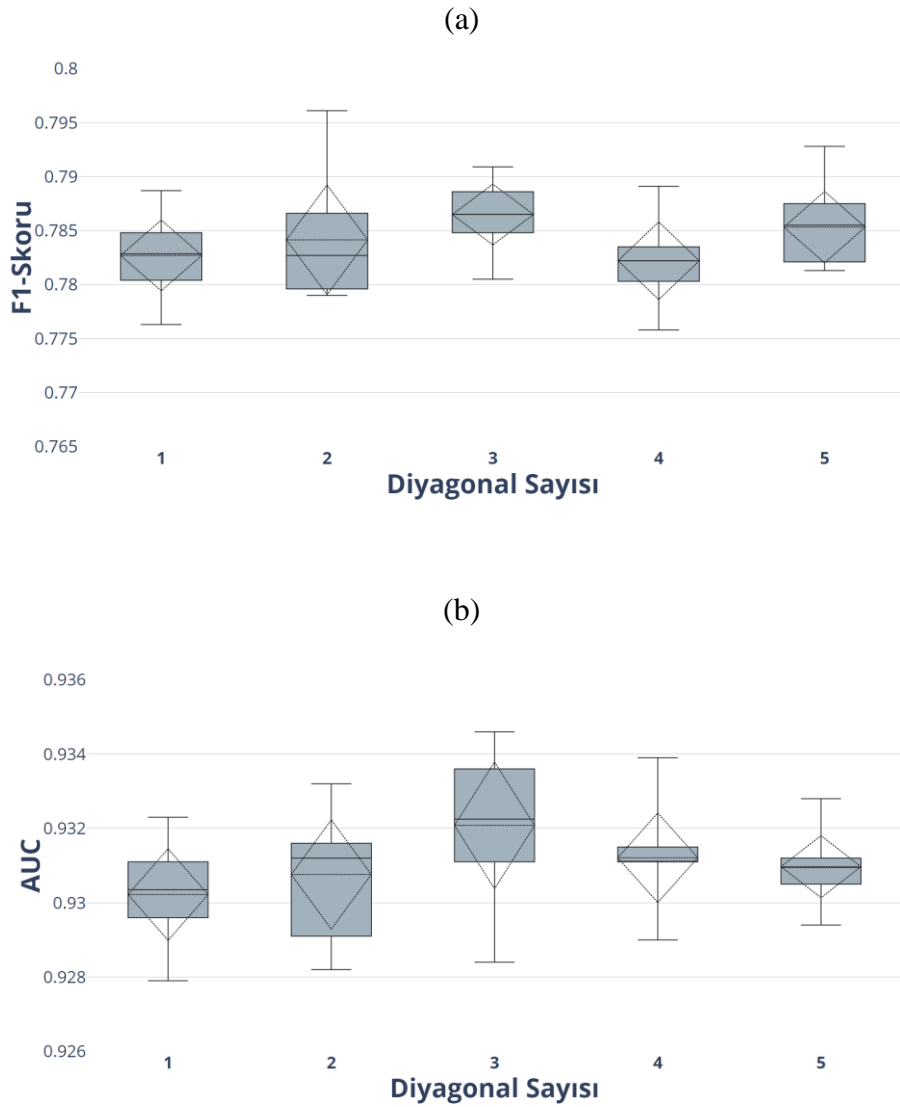
Normalleştirilmiş orijinal veri ile ilk köşegen verisinin birleşimi, her iki verinin ayrı ayrı sınıflandırıldığı yaklaşımlara göre daha iyi sınıflandırma başarısı vermektedir. Ayrıca Normalleştirilmiş veri ile derece değer verilerinin birleşiminin sınıflandırılması, derece değerlerinin tek başına sınıflandırıldığı yaklaşıma göre daha iyi sonuçlar vermektedir.

Çizelge 7.1. Test edilen tüm özellik setleri ve ağ modellerine ait sınıflandırma sonuçları.

Özellik Seti	Sınıflandırıcı	Ortalama Sonuçlar			Maksimum Sonuçlar		
		Doğruluk (SS)	F1-Skoru (SS)	AUC (SS)	Doğruluk	F1-Skoru	AUC
Orij. Veri	Resnet1d_wang	0,8855 (0,002)	0,7752 (0,004)	0,9263 (0,001)	0,8905	0,7814	0,9281
Orij. Veri	Inception1d	0,8811 (0,001)	0,7658 (0,004)	0,9206 (0,002)	0,8842	0,7681	0,9233
Orij. Veri (Normalize)	Resnet1d_wang	0,8887 (0,002)	0,7785 (0,004)	0,9288 (0,001)	0,8911	0,7835	0,9302
Orij. Veri (Normalize)	Inception1d	0,8873 (0,001)	0,7751 (0,003)	0,9265 (0,001)	0,8873	0,7738	0,9284
Düğüm Derece Değerleri	Resnet1d_wang	0,8871 (0,002)	0,7756 (0,002)	0,9270 (0,001)	0,8865	0,7751	0,9291
Düğüm Derece Değerleri	Inception1d	0,8866 (0,002)	0,7738 (0,004)	0,9238 (0,001)	0,89	0,7811	0,9271
Komş. M. (İlk diyagonal)	Resnet1d_wang	0,8909 (0,001)	0,7827 (0,003)	0,9302 (0,001)	0,8924	0,7862	0,9323
Komş. M. (İlk 2 diyagonal)	Resnet1d_wang (2 Channel CNN)	0,8917 (0,002)	0,7841 (0,005)	0,9308 (0,001)	0,8971	0,7961	0,9332
Komş. M. (İlk 3 diyagonal)	Resnet1d_wang (3 Channel CNN)	0,8926 (0,002)	0,7865 (0,003)	0,9321 (0,002)	0,8945	0,7893	0,9346
Komş. M. (İlk 4 diyagonal)	Resnet1d_wang (4 Channel CNN)	0,8907 (0,002)	0,7822 (0,004)	0,9312 (0,001)	0,8947	0,7891	0,9339
Komş. M. (İlk 5 diyagonal)	Resnet1d_wang (5 Channel CNN)	0,8920 (0,001)	0,7853 (0,003)	0,9309 (0,001)	0,8952	0,7928	0,9328
Komş. M. (İlk diyagonal)	Inception1d	0,8903 (0,001)	0,7820 (0,003)	0,9288 (0,001)	0,8888	0,7871	0,9296
Komş. M. (İlk 3 diyagonal)	Inception1d (3 Channel CNN)	0,8902 (0,001)	0,7816 (0,002)	0,9292 (0,001)	0,8937	0,7903	0,9316
Komş. M. (İlk 5 diyagonal)	Inception1d (5 Channel CNN)	0,8903 (0,002)	0,7826 (0,004)	0,9291 (0,001)	0,892	0,7869	0,9312
Orij. Veri + Komş. M. (İlk d.)	Resnet1d_wang (2 Channel CNN)	0,8922 (0,001)	0,7858 (0,002)	0,9317 (0,001)	0,8925	0,7865	0,9327
Orij. Veri + Komş. M. (İlk d.)	Inception1d (2 Channel CNN)	0,8903 (0,001)	0,7814 (0,003)	0,9291 (0,001)	0,8914	0,7837	0,9304
Orij. Veri + Düğüm Der.	Resnet1d_wang (2 Channel CNN)	0,8892 (0,002)	0,7796 (0,004)	0,9286 (0,001)	0,8904	0,7815	0,9294
Orij. Veri + Düğüm Der.	Inception1d (2 Channel CNN)	0,8880 (0,002)	0,7774 (0,004)	0,9272 (0,001)	0,8892	0,7791	0,9289

Çizelge 7.1’de ham veri, ağ dönüşümünden elde edilen özellik vektörleri ve bunların kombinasyonlarından oluşan girdilere ait olmak üzere, bu tez çalışmasında

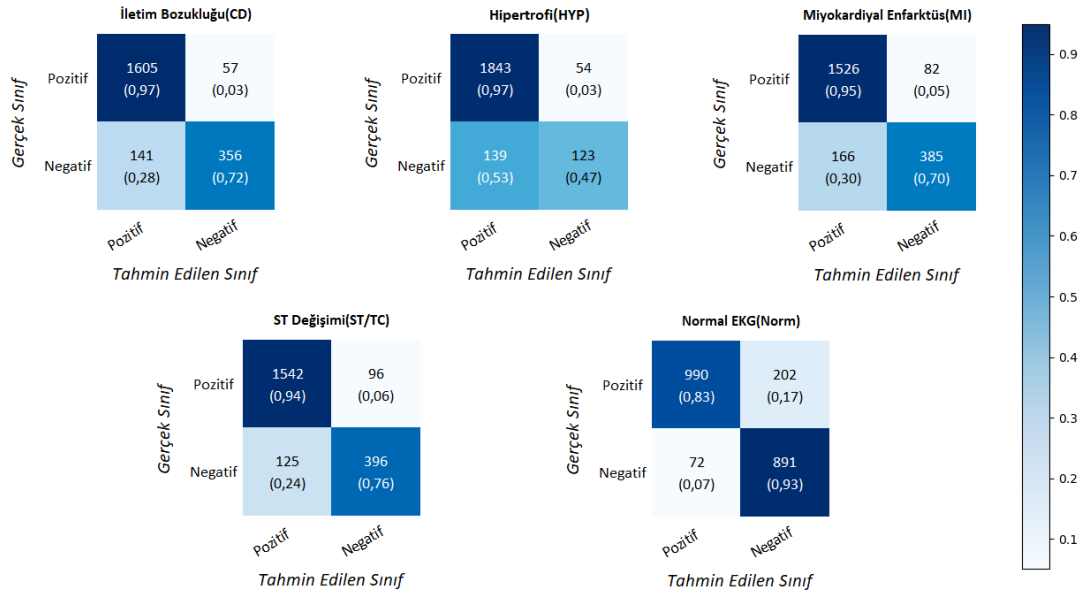
gerçekleştirilmiş olan tüm deney setlerine ait sınıflandırma sonuçları özetlenerek sunulmuştur. Ayrıca Şekil 7.1’de komşuluk matrisinin ilk n köşegenlerinin öznelik seti olarak kullanımı sonucu elde edilen sınıflandırma başarımlarına ait kutu-grafikler verilmiştir. Kutu grafikleri incelendiğinde hem F1-Skoru hem de AUC değeri için ilk 3 köşegeni içeren çalışmanın daha başarılı sonuçlar verdiği görülmektedir. Kullanılan köşegen sayısı arttıkça sınıflandırma başarı trendi düşme eğilimindedir. Dolayısıyla sınıflandırma başarısını artırmak için daha fazla köşegen (ve dolayısıyla kaynak) ihtiyacının olmadığı ortaya çıkmaktadır.



Şekil 7.1. Görünürlük grafiği temsillerinin komşuluk matrisinin ilk n köşegeni için sınıflandırma sonuçları. Her 10 denemeden sonra hesaplanan (a) F1-Skoru, (b) AUC Metrikleri.

Şekil 7.2’de en başarılı öznelik seti olan komşuluk matrisinin ilk 3 köşegeninin 3 kanallı ResNet ağı ile sınıflandırılmasının ardından oluşan, her bir sınıfa ait doğruluk matrisleri verilmiştir.

Doğruluk matrisleri incelendiğinde doğru pozitiflik (TP) değeri en yüksek olan sınıfların 0,97 oranı İletim Bozukluğu (CD) ve Hipertrofi (HYP) olduğu görülmektedir. Miyokardiyal Enfarktüs (MI) sınıfı 0,95, ST/T Değişimi (ST/T) sınıfı 0,94 ve Normal EKG (Norm) sınıfı 0,83 doğru pozitiflik değerlerini almıştır. Diğer yandan doğru negatiflik değeri en yüksek olan sınıf 0,93 değeri ile Normal EKG (Norm) sınıfıdır. Geri kalan dört sınıfın doğru negatiflik değerleri 0,46-0,76 arası değerler almaktadır. Bu sonuçlar sınıflandırıcının tüm sınıflar için gerçek pozitifleri daha iyi tanıladığını, mevcut hata oranının ise ağırlıklı olarak negatif etiketli örneklerdeki sınıflandırma başarısının daha düşük olmasından kaynaklandığını ortaya koymaktadır.



Şekil 7.2. Komşuluk matrisinin ilk 3 köşegeni kullanılarak yapılan en iyi deneme sonucu oluşan doğruluk matrisi.

Bu tez çalışmasında görünürlük ağ dönüşümü yaklaşımı ile elde edilen %89,71 doğruluk, %79,61 F1-Skoru ve %93,46 AUC metrikleri değerlendirildiğinde daha

önce aynı veri setini kullanan çalışmalara oranla daha iyi sınıflandırma performansı elde edildiği anlaşılmaktadır. Bu alandaki en güncel çalışmalarla yapılan özet bir karşılaştırma Çizelge 7.2’de verilmiştir. En iyi performans gösterenlere göre gerçekleşen küçük iyileştirme, sinyal sınıflandırma görevlerinde graf tabanlı yaklaşımların potansiyelini göstermektedir.

Çizelge 7.2. Mevcut çalışmanın sınıflandırma performansının yakın zamanda yapılan çeşitli çalışmalarla özet karşılaştırması.

Çalışma	Mimari	Veri Kullanımı	AUC	F1-Skoru
[32]	Resnet1d_wang	21430 kayıt (foldlar 1-8 eğitim, 9 doğrulama, 10 test)	%93	-
[73]	MLBF-NET	21430 kayıt (foldlar 1-8 eğitim, 9 doğrulama, 10 test)	%93,10	-
[115]	ST-CNN-GAP-5	21837 kayıt (foldlar 1-9 eğitim (%88) + doğrulama (%12), 10 test)	%93,41	%79,28
[116]	CNN+ entropi özellikleri	17232 kayıt (%70 eğitim, %15 doğrulama, %15 test)	%91,00	%68,00
[110]	FSL+ Doğrusal Çekirdekli DVM	17232 kayıt (%70 eğitim, %15 doğrulama, %15 test)	%93,80	%71,70
[113]	33-katmanlı CNN Mimarisi + NCBAM	21837 kayıt (%80 eğitim, %20 test)	%93,14	-
[117]	2D-CNN+DKR-block	21837 kayıt (foldlar 1-8 eğitim, 9 doğrulama, 10 test)	%92,9	%77
[112]	11-layer CNN	17232 kayıt (%70 eğitim, %15 doğrulama, %15 test)	%90,3	%68
Mevcut Çalışma	Resnet1d_wang	21396 kayıt (folds 1-8 eğitim, 9 doğrulama, 10 test)	%93,46	%79,61

Ağlar, derin öğrenmede veri temsilleri için yeni ve etkili alternatiflerdir. EKG sinyallerinin görünürlük ağ temsillerinden türetilen özellik setlerinin, orijinal verilere kıyasla daha iyi sınıflandırma sonuçları sağlayıp sağlamadığı test edilmiştir. Sonuçlar, görünürlük ağı komşuluk matrislerinden elde edilen köşegenlerin, EKG sınıflandırma performansını iyileştirmek için verimli özellik kümeleri sunduğunu ve derin öğrenme modellerine girdi sağlayan tüm alternatif özellik kümelerinden daha iyi performans

gösterdiğini göstermektedir. Bu aynı zamanda görünürlük ağının orijinal zaman serisinin özelliklerini koruduğunu ve gizli örüntülerin keşfedilmesini kolaylaştırdığını gösterir ki bu da ağ biliminin yapay zekâ alanına önemli bir katkısı olarak kabul edilebilir.

Tez çalışmasında özellik çıkartımı için çalışma zamanı bilgileri incelendiğinde; görünürlük graf dönüşümü yaklaşımının çalışma zamanını artırdığı gözlenmektedir. PTB-XL veri setindeki bir kayıt için fazladan ~0,6ms, tüm kayıtlar için ise fazladan ~213,97dk'ya ihtiyaç duyulmaktadır. Bu da zaman serilerinin görünürlük grafları ile dönüşümünün hesaplama yükü açısından çeşitli sınırlamalara sahip olduğunu göstermektedir. Graf dönüşümü için kullanılan ağırlıklı görünürlük grafının zaman karmaşıklığı $O(n \log n)$ olup doğrusal logaritmiktir (linearitmik). İşleme tabi tutulan veri sayısı arttıkça doğrusal ve logaritmik olma özelliği ile zaman karmaşıklığı artmaktadır. İşlenen veri sayısı graf dönüşümü için önemlidir. Komşuluk matrisinin boyutu, işlenen zaman noktalarının sayısı (veya verinin zaman çözünürlüğü) ile doğrudan ilişkilidir. Bu nedenle çok uzun zaman verileri, nokta sayısının azalacağı şekilde örneklenmeli veya makul bir düzeyde örtüşecek şekilde sabit uzunluklu zaman pencereleri ile işlenmelidir. Ayrıca ağdaki bağlantı ağırlıklarını tanımlayan arctan() fonksiyonu sınıflandırma başarısını artıran bir unsurdur. Fakat ekstra bir işlem yükü getirmektedir. Son olarak sinyal gürültülerinden kaynaklanan olgular, örneğin geçiş düzensizlikleri görünürlük ağını olumsuz etkileyebilmektedir. Bu sorunu gidermek için bir ön işleme ile gürültüler giderilebilir. Bu sınırlandırmalar nedeniyle görünürlük grafi yaklaşımı kullanılmadan önce veri; boyutu, örnekleme frekansı ve sinyal kalitesi açısından ele alınmalıdır.

Sınıflandırma uygulaması açısından çalışma zamanı incelendiğinde ise en iyi sınıflandırma başarısının elde edildiği ilk 3 köşegen verisinde eğitim için geçen süre orijinal veri ile eğitime kıyasla yaklaşık %60 daha uzundur. Bu da eğitimde kullanılan veri sayısı miktarının orijinal veriye göre 3 kat fazla olması ve sınıflandırıcı model için kullanılan çok kanallı mimariden kaynaklanmaktadır. Bununla birlikte orijinal veriye göre yapılan sınıflandırma denemelerine göre %0,39'luk bir iyileştirme sağlamaktadır. Test verilerinin sınıflandırılması için geçen süre ise ilk 3 köşegen veri için 4sn, orijinal veri için 2sn sürmektedir.

Literatürde yapılan çalışmalar dikkate alındığında test sonuçlarının birbirine yakın skalada olduğu görülmektedir. Görünürlük grafları ile yapılan bu çalışmada çalışma zamanı maliyetlerinin artmasının yanında sınıflandırma başarısında minör artış sağlanmıştır. Bu durum, PTB-XL veri setinin boyutu dikkate alındığında gerçek zamanlı bir EKG tanı sistemine dönüşümü açısından dezavantaj teşkil etmektedir. Özellikle eğitim için geçen süre hem orijinal veri için hem de çıkartılan özellikler için uzundur. Ancak transfer öğrenme yaklaşımı ile önceden eğitilmiş ağ ve hesaplanan sinir hücre arası ağırlıkları ile yeni bir EKG sinyalinin sınıflandırma işlemi hızlı bir şekilde gerçekleştirilebilir. Bu nedenle minör iyileştirmelerin önem arz ettiği medikal sınıflandırma uygulamalarında ağın eğitim süresinin uzunluğu kabul edilebilir bir durum olarak değerlendirilebilir.

Görünürlük grafları ve bunların alt varyantı olan ağırlıklı görünürlük grafları, nöbet tespiti, uyku tespiti, sinyal füzyonu gibi uygulamalarda zaman serisini karmaşık bir ağa dönüştürerek orijinal verinin dinamik özelliklerini yakalamaktadır. Bu uygulamalara ilişkin [179–181] çalışmaları bulunmaktadır. Çalışmamız, ağırlıklı görünürlük grafi temsilinden özellikler çıkartarak, kalp durumlarını başarılı bir şekilde sınıflandırmaktadır. Ayrıca, graf oluşturma stratejisinin sabit-uzunluklu kayan pencerelere uygulanması durumunda gerçek zamanlı durum değişikliklerini tespit etme potansiyeline sahiptir. Bu yaklaşım, ardışık zaman pencerelerinden graf yapısındaki değişikliklerin izlenmesini sağlayarak zaman içindeki durum değişikliklerinin tespit edilmesini de sağlama potansiyeline sahiptir.

KAYNAKLAR

1. Watts, D. J. and Strogatz, S. H., "Collective dynamics of small-world networks", *Nature*, 393 (6684): 440–442 (1998).
2. Albert, R. and Barabási, A. L., "Statistical mechanics of complex networks", *Reviews Of Modern Physics*, 74 (1): 47–97 (2002).
3. Bonato, A. and Tian, Y., "Complex Networks and Social Networks", *Advances in Network Analysis and its Applications*, 269–286 (2012).
4. Cao, L., "Complex systems", *Advanced Information and Knowledge Processing*, 1–36 (2015).
5. Braik, M., Sheta, A., and Arieqat, A., "A Comparison between GAs and PSO in Training ANN to Model the TE Chemical Process Reactor", *Proceedings Of The AISB 2008 Symposium On Swarm Intelligence Algorithms And Applications*, (October 2016): 24–31 (2008).
6. Barabási, A.-L., "Network science introduction", *Network Science*, 1–27 (2016).
7. Schlichtkrull, M., Kipf, T. N., Bloem, P., van den Berg, R., Titov, I., and Welling, M., "Modeling Relational Data with Graph Convolutional Networks", *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 10843 LNCS (1): 593–607 (2018).
8. Zhang, M., Cui, Z., Neumann, M., and Chen, Y., "An end-to-end deep learning architecture for graph classification", *32nd AAAI Conference On Artificial Intelligence, AAAI 2018*, 4438–4445 (2018).
9. Vishwanathan, S. V. N. and Schraudolph, N. N., "Graph Kernels", *The Journal of Machine Learning Research*, 11: 1201–1242 (2010).
10. Yanardag, P., Lafayette, W., and Vishwanathan, S. V. N., "Deep Graph Kernels", *In Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '15)*, New York, (2015).
11. Moonesinghe, H. D. K., Valizadegan, H., Fodeh, S., and Tan, P. N., "A probabilistic substructure-based approach for graph classification", *Proceedings - International Conference On Tools With Artificial Intelligence, ICTAI*, 1: 346–349 (2007).
12. Prieto, L. P., Rodríguez-Triana, M. J., Kusmin, M., and Laanpere, M., "Graph2Vec", *CEUR Workshop Proceedings*, 1828: 53–59 (2017).

13. Gasparetto, A., Minello, G., and Torsello, A., "A non-parametric spectral model for graph classification", *ICPRAM 2015 - 4th International Conference On Pattern Recognition Applications And Methods, Proceedings*, 1: 312–319 (2015).
14. Adhikari, B., Zhang, Y., Ramakrishnan, N., and Prakash, B. A., "Sub2Vec: Feature learning for subgraphs", *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 10938 LNAI: 170–182 (2018).
15. Gu, S. and Milenkovic, T., "Graphlets versus node2vec and struc2vec in the task of network alignment", *CoRR*, abs/1805.04222: 1–11 (2018).
16. Grover, A. and Leskovec, J., "node2vec: Scalable Feature Learning for Networks", *CoRR*, abs/1607.00653, 855–864 (2016).
17. Li, W., Wang, H., Zhuang, L., Han, S., Zhang, H., and Wang, J., "Weighted multi-scale limited penetrable visibility graph for exploring atrial fibrillation rhythm", *Signal Processing*, 189: (2021).
18. Ismail Fawaz, H., Forestier, G., Weber, J., Idoumghar, L., and Muller, P. A., "Deep learning for time series classification: a review", *Data Mining And Knowledge Discovery*, 33 (4): (2019).
19. Silva, V. F., Silva, M. E., Ribeiro, P., and Silva, F., "Time series analysis via network science: Concepts and algorithms", *Wiley Interdisciplinary Reviews: Data Mining And Knowledge Discovery*, 11 (3): (2021).
20. Türker İ and Tan SO, "A codeword-based graph representation for time series", *8th INTERNATIONAL ASIAN CONGRESS ON CONTEMPORARY SCIENCES 1 (1)*, 48-52 (2023).
21. Turker, I. and Tan, S. O., "Scientific Impact of Graph-Based Approaches in Deep Learning Studies -- A Bibliometric Comparison", *arXiv:2210.07343* (2022).
22. Karthik, S., Santhosh, M., Kavitha, M. S., and Paul, A. C., "Automated Deep Learning Based Cardiovascular Disease Diagnosis Using ECG Signals", *Computer Systems Science And Engineering*, 42 (1): (2022).
23. Pineda, A. M., Ramos, F. M., Betting, L. E., and Campanharo, A. S. L. O., "Quantile graphs for EEG-based diagnosis of Alzheimer's disease", *PLoS ONE*, 15 (6): (2020).
24. Kose, M. R., Ahirwal, M. K., and Kumar, A., "A new approach for emotions recognition through EOG and EMG signals", *Signal, Image And Video Processing*, 15 (8): (2021).
25. Wagner, P., Strodthoff, N., Boussejot, R. D., Kreiseler, D., Lunze, F. I., Samek, W., and Schaeffter, T., "PTB-XL, a large publicly available electrocardiography dataset (version 1.0.2)", *PhysioNet*, (2022).

26. Liu, X., Wang, H., Li, Z., and Qin, L., "Deep learning in ECG diagnosis: A review", *Knowledge-Based Systems*, 227: (2021).
27. Varatharajan, R., Manogaran, G., and Priyan, M. K., "A big data classification approach using LDA with an enhanced SVM method for ECG signals in cloud computing", *Multimedia Tools And Applications*, 77 (8): (2018).
28. Celin, S. and Vasanth, K., "ECG Signal Classification Using Various Machine Learning Techniques", *Journal Of Medical Systems*, 42 (12): (2018).
29. Cai, L., Chen, C., Wang, X., Yang, X., Lin, S., Huang, J., Jiang, J., Datta, R., Du, M., Jiang, H., Zhu, M., and Huang, J., "Sleep Disorder Classification Method based on Logistic Regression with Apnea-ECG Dataset", *Proceedings of the 2019 International Conference on Artificial Intelligence and Advanced Manufacturing*, New York, (2019).
30. Diker, A., Avci, E., Comert, Z., Avci, D., Kacar, E., and Serhatlioglu, I., "Classification of ECG signal by using machine learning methods", *2018 26th Signal Processing and Communications Applications Conference (SIU)*, İzmir, (2018).
31. Mohebbanaaz, Kumari, L. V. R., and Sai, Y. P., "Classification of ECG beats using optimized decision tree and adaptive boosted optimized decision tree", *Signal, Image And Video Processing*, 16 (3): (2022).
32. Strodthoff, N., Wagner, P., Schaeffter, T., and Samek, W., "Deep Learning for ECG Analysis: Benchmarks and Insights from PTB-XL", *IEEE Journal Of Biomedical And Health Informatics*, 25 (5): (2021).
33. van Steenkiste, G., van Loon, G., and Crevecoeur, G., "Transfer Learning in ECG Classification from Human to Horse Using a Novel Parallel Neural Network Architecture", *Scientific Reports*, 10 (1): (2020).
34. Lynn, H. M., Pan, S. B., and Kim, P., "A Deep Bidirectional GRU Network Model for Biometric Electrocardiogram Classification Based on Recurrent Neural Networks", *IEEE Access*, 7: (2019).
35. Singh, S., Pandey, S. K., Pawar, U., and Janghel, R. R., "Classification of ECG Arrhythmia using Recurrent Neural Networks", *Procedia Computer Science*, 13: (2018).
36. Saadatnejad, S., Oveisi, M., and Hashemi, M., "LSTM-Based ECG Classification for Continuous Monitoring on Personal Wearable Devices", *IEEE Journal Of Biomedical And Health Informatics*, 24 (2): (2020).
37. Salem, M., Taheri, S., and Yuan, J. S., "ECG Arrhythmia Classification Using Transfer Learning from 2- Dimensional Deep CNN Features", *2018 IEEE Biomedical Circuits and Systems Conference (BioCAS)*, Cleveland (2018).

38. Baloglu, U. B., Talu, M., Yildirim, O., Tan, R. S., and Acharya, U. R., "Classification of myocardial infarction with multi-lead ECG signals and deep CNN", *Pattern Recognition Letters*, 122: (2019).
39. Arpitha, Y., Madhumathi, G. L., and Balaji, N., "Spectrogram analysis of ECG signal and classification efficiency using MFCC feature extraction technique", *Journal Of Ambient Intelligence And Humanized Computing*, 13 (2): (2022).
40. Li, H. and Boulanger, P., "Structural Anomalies Detection from Electrocardiogram (ECG) with Spectrogram and Handcrafted Features", *Sensors*, 22 (7): (2022).
41. Sayin, F. S. and Akgun, O., "Higher order spectral analysis of ventricular arrhythmic ECG Signals with MATLAB HOSA toolbox", *2018 6th International Conference on Control Engineering & Information Technology (CEIT)*, İstanbul, (2018).
42. Mian Qaisar, S. and Hussain, S. F., "An effective arrhythmia classification via ECG signal subsampling and mutual information based subbands statistical features selection", *Journal Of Ambient Intelligence And Humanized Computing*, (2021).
43. Yang, H. and Wei, Z., "Arrhythmia Recognition and Classification Using Combined Parametric and Visual Pattern Features of ECG Morphology", *IEEE Access*, 8: (2020).
44. Lin, Y.-T., Malik, J., and Wu, H.-T., "Wave-shape oscillatory model for biomedical time series with applications", *Wave-Shape Oscillatory Model For Biomedicine*, 2019.
45. Li, H., An, Z., Zuo, S., Zhu, W., Cao, L., Mu, Y., Song, W., Mao, Q., Zhang, Z., Li, E., and García, J. D. P., "Classification of electrocardiogram signals with waveform morphological analysis and support vector machines", *Medical And Biological Engineering And Computing*, 60 (1): (2022).
46. Zhao, Y., Cheng, J., Zhang, P., and Peng, X., "ECG classification using deep CNN improved by wavelet transform", *Computers, Materials And Continua*, 64 (3): (2020).
47. Wang, T., Lu, C., Sun, Y., Yang, M., Liu, C., and Ou, C., "Automatic ECG classification using continuous wavelet transform and convolutional neural network", *Entropy*, 23 (1): (2021).
48. Ebrahimi, Z., Loni, M., Daneshtalab, M., and Gharehbaghi, A., "A review on deep learning methods for ECG arrhythmia classification", *Expert Systems with Applications: X*, (2020)
49. Cheng, Z., Yang, Y., Jiang, S., Hu, W., Ying, Z., Chai, Z., and Wang, C., "Time2Graph+: Bridging Time Series and Graph Representation Learning via Multiple Attention", *IEEE Transactions On Knowledge And Data Engineering*, (2021).

50. Türker, İ. and Aksu, S., "Connectogram – A graph-based time dependent representation for sounds", *Applied Acoustics*, 191: (2022).
51. Cai, Q., Gao, Z., An, J., Gao, S., and Grebogi, C., "A Graph-Temporal Fused Dual-Input Convolutional Neural Network for Detecting Sleep Stages from EEG Signals", *IEEE Transactions On Circuits And Systems II: Express Briefs*, 68 (2): (2021).
52. AKSU, S. and TÜRKER, İ., "VarioGram – A colorful time-graph representation for time series", *Bilgi ve İletişim Teknolojileri Dergisi*, 4 (2): 128–142 (2022).
53. Grabocka, J., Schilling, N., Wistuba, M., and Schmidt-Thieme, L., "Learning time-series shapelets", *In Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining (KDD '14)*, New York, (2014).
54. Lacasa, L., Luque, B., Ballesteros, F., Luque, J., and Nuño, J. C., "From time series to complex networks: The visibility graph", *Proceedings Of The National Academy Of Sciences Of The United States Of America*, 105 (13): (2008).
55. Luque, B., Lacasa, L., Ballesteros, F., and Luque, J., "Horizontal visibility graphs: Exact results for random time series", *Physical Review E - Statistical, Nonlinear, And Soft Matter Physics*, 80 (4): (2009).
56. Zhou, T. T., Jin, N. de, Gao, Z. K., and Luo, Y. bin, "Limited penetrable visibility graph for establishing complex network from time series", *Wuli Xuebao/Acta Physica Sinica*, 61 (3): (2012).
57. Supriya, S., Siuly, S., Wang, H., Cao, J., and Zhang, Y., "Weighted Visibility Graph with Complex Network Features in the Detection of Epilepsy", *IEEE Access*, 4: (2016).
58. Kulp, C. W., Chobot, J. M., Freitas, H. R., and Sprechini, G. D., "Using ordinal partition transition networks to analyze ECG data", *Chaos*, 26 (7): (2016).
59. Yang, Y. and Yang, H., "Complex network-based time series analysis", *Physica A: Statistical Mechanics And Its Applications*, 387 (5–6): (2008).
60. Zhang, J., Luo, X., and Small, M., "Detecting chaos in pseudoperiodic time series without embedding", *Physical Review E - Statistical, Nonlinear, And Soft Matter Physics*, 73 (1): (2006).
61. Marwan, N., Donges, J. F., Zou, Y., Donner, R. v., and Kurths, J., "Complex network approach for recurrence analysis of time series", *Physics Letters, Section A: General, Atomic And Solid State Physics*, 373 (46): (2009).
62. Lan, X., Mo, H., Chen, S., Liu, Q., and Deng, Y., "Fast transformation from time series to visibility graphs", *Chaos*, 25 (8): (2015).
63. Çınar, A. and Tuncer, S. A., "Classification of normal sinus rhythm, abnormal arrhythmia and congestive heart failure ECG signals using LSTM and hybrid

- CNN-SVM deep neural networks", *Computer Methods In Biomechanics And Biomedical Engineering*, 24 (2): (2021).
64. Denes, P., Garside, D. B., Lloyd-Jones, D., Gouskova, N., Soliman, E. Z., Ostfeld, R., Zhang, Z. M., Camacho, A., Prineas, R., Raij, L., and Daviglus, M. L., "Major and minor electrocardiographic abnormalities and their association with underlying cardiovascular disease and risk factors in Hispanics/Latinos (from the Hispanic Community Health Study/Study of Latinos)", *American Journal Of Cardiology*, 112 (10): (2013).
 65. Monedero, I., "A novel ECG diagnostic system for the detection of 13 different diseases", *Engineering Applications Of Artificial Intelligence*, 107: (2022).
 66. Odinaka, I., Lai, P. H., Kaplan, A. D., O'Sullivan, J. A., Sirevaag, E. J., and Rohrbaugh, J. W., "ECG biometric recognition: A comparative analysis", *IEEE Transactions On Information Forensics And Security*, 7 (6): (2012).
 67. Mirahmadizadeh, A., Farjam, M., Sharafi, M., Fatemian, H., Kazemi, M., Geraylow, K. R., Dehghan, A., Amiri, Z., and Afrashteh, S., "The relationship between demographic features, anthropometric parameters, sleep duration, and physical activity with ECG parameters in Fasa Persian cohort study", *BMC Cardiovascular Disorders*, 21 (1): (2021).
 68. Selvan, S. S., Arjunan, S. P., Swaminathan, R., and Kumar, D. K., "Complexity Analysis in the PR, QT, RR and ST Segments of ECG for Early Assessment of Severity in Cardiac Autonomic Neuropathy", *Applied Sciences (Switzerland)*, 12 (11): (2022).
 69. Rodríguez-Sotelo, J. L., Cuesta-Frau, D., and Castellanos-Dominguez, G., "Unsupervised classification of atrial heartbeats using a prematurity index and wave morphology features", *Medical And Biological Engineering And Computing*, 47 (7): (2009).
 70. Kim, J., Sung, D., Koh, M. J., Kim, J., and Park, K. S., "Electrocardiogram authentication method robust to dynamic morphological conditions", *IET Biometrics*, 8 (6): (2019).
 71. Lilly, L. S., "Pathophysiology of Heart Disease: A Collaborative Project of Medical Students and Faculty: Fifth Edition", *Lippincott Williams & Wilkins*, (2013).
 72. Davey, P. and Sharman, D., "The Electrocardiogram", *Medicine*, 50:(2022)
 73. Zhang, J., Liang, D., Liu, A., Gao, M., Chen, X., Zhang, X., and Chen, X., "MLBF-Net: A Multi-Lead-Branch Fusion Network for Multi-Class Arrhythmia Classification Using 12-Lead ECG", *IEEE Journal Of Translational Engineering In Health And Medicine*, 9: (2021).
 74. Li, H., Yuan, D., Wang, Y., Cui, D., and Cao, L., "Arrhythmia classification based on multi-domain feature extraction for an ECG recognition system", *Sensors (Switzerland)*, 16 (10): (2016).

75. Saminu, S., Ozkurt, N., and Karaye, I. A., "Wavelet feature extraction for ECG beat classification", *2014 IEEE 6th International Conference on Adaptive Science & Technology (ICAST)*, Ota, Nigeria, (2015).
76. Balachandran, A., Ganesan, M., and Sumesh, E. P., "Daubechies algorithm for highly accurate ECG feature extraction", *2014 International Conference on Green Computing Communication and Electrical Engineering (ICGCCEE)*, Coimbatore, India, (2014).
77. Kar, A. and Das, L., "A Technical Review on Statistical Feature Extraction of ECG signal", *IJCA Special Issue On "2nd National Conference-Computing, Communication And Sensor Network,"* (2011).
78. Li, H., Yuan, D., Ma, X., Cui, D., and Cao, L., "Genetic algorithm for the optimization of features and neural networks in ECG signals classification", *Scientific Reports*, 7: (2017).
79. Alotaiby, T. N., Alrshoud, S. R., Alshebeili, S. A., and Aljafar, L. M., "ECG-Based Subject Identification Using Statistical Features and Random Forest", *Journal Of Sensors*, 2019: (2019).
80. Devi, R. L. and Kalaivani, V., "Machine learning and IoT-based cardiac arrhythmia diagnosis using statistical and dynamic features of ECG", *Journal Of Supercomputing*, 76 (9): (2020).
81. Mar, T., Zaunseder, S., Martínez, J. P., Llamedo, M., and Poll, R., "Optimization of ECG classification by means of feature selection", *IEEE Transactions On Biomedical Engineering*, 58 (8): (2011).
82. Tiinanen, S., Noponen, K., Tulppo, M., Kiviniemi, A., and Seppänen, T., "ECG-derived respiration methods: Adapted ICA and PCA", *Medical Engineering And Physics*, 37 (5): (2015).
83. Xueyun, W. and Wei, Z., "Application of kernel PCA for foetal ECG estimation", *Electronics Letters*, 54 (6): (2018).
84. Martis, R. J., Acharya, U. R., and Min, L. C., "ECG beat classification using PCA, LDA, ICA and Discrete Wavelet Transform", *Biomedical Signal Processing And Control*, 8 (5): (2013).
85. Ghaemi, M. and Feizi-Derakhshi, M.-R., "Feature selection using Forest Optimization Algorithm", *Pattern Recognition*, 60: 121–129 (2016).
86. Hamza, S. and Ayed, Y. Ben, "SVM for human identification using the ECG signal", *Procedia Computer Science*, 176:430-439 (2020).
87. Li, N., Zhu, L., Ma, W., Wang, Y., He, F., Zheng, A., and Zhang, X., "The Identification of ECG Signals Using WT-UKF and IPSO-SVM", *Sensors*, 22 (5): (2022).

88. Venkatesan, C., Karthigaikumar, P., Paul, A., Satheeskumaran, S., and Kumar, R., "ECG Signal Preprocessing and SVM Classifier-Based Abnormality Detection in Remote Healthcare Applications", *IEEE Access*, 6: (2018).
89. Mandala, S., Cai Di, T., Sunar, M. S., and Adiwijaya, "ECG-based prediction algorithm for imminent malignant ventricular arrhythmias using decision tree", *PLoS ONE*, 15 (5): (2020).
90. Mert, A., Kilic, N., and Akan, A., "ECG Signal Classification Using Ensemble Decision Tree", *Ecg Signal Classification Using Ensemble Decision Tree*, (September): (2012).
91. Fikri, M. R., Soesanti, I., and Nugroho, H. A., "ECG Signal Classification Review", *IJITEE (International Journal Of Information Technology And Electrical Engineering)*, 5 (1): (2021).
92. Al-Huseiny, M. S., Abbas, N. K., and Sajit, A. S., "Diagnosis of arrhythmia based on ECG analysis using CNN", *Bulletin Of Electrical Engineering And Informatics*, 9 (3): (2020).
93. Hochreiter, S. and Schmidhuber, J., "Long Short-Term Memory", *Neural Computation*, 9 (8): 1735–1780 (1997).
94. Noor, S. T., Asad, S. T., Khan, M. M., Gaba, G. S., Al-Amri, J. F., and Masud, M., "Predicting the Risk of Depression Based on ECG Using RNN", *Computational Intelligence And Neuroscience*, 2021: (2021).
95. Sampath, A. and Sumithira, T. R., "Sparse based recurrent neural network long short term memory (rnn-lstm) model for the classification of ecg signals", *Applied Artificial Intelligence*, 36 (1): (2022).
96. Obeidat, Y. and Alqudah, A. M., "A Hybrid lightweight 1D CNN-LSTM architecture for automated ECG beat-wise classification", *Traitement Du Signal*, 38 (5): (2021).
97. Xu, X., Jeong, S., and Li, J., "Interpretation of Electrocardiogram (ECG) Rhythm by Combined CNN and BiLSTM", *IEEE Access*, 8: (2020).
98. Abdullah, L. A. and Al-Ani, M. S., "CNN-LSTM based model for ECG arrhythmias and myocardial infarction classification", *Advances In Science, Technology And Engineering Systems*, 5 (5): (2020).
99. Wang, Z., Yan, W., and Oates, T., "Time series classification from scratch with deep neural networks: A strong baseline", *CoRR*, abs/1611.06455 (2017).
100. McCullough, M., Small, M., Iu, H. H. C., and Stemler, T., "Multiscale ordinal network analysis of human cardiac dynamics", *Philosophical Transactions Of The Royal Society A: Mathematical, Physical And Engineering Sciences*, 375 (2096): (2017).

101. Zhang, J. and Small, M., "Complex network from pseudoperiodic time series: Topology versus dynamics", *Physical Review Letters*, 96 (23): (2006).
102. Ma, Z. Y., Yang, X. D., He, A. J., Ma, L., and Wang, J., "Complex network recognition of electrocardiograph signals in health and myocardial infarction patients based on multiplex visibility graph", *Wuli Xuebao/Acta Physica Sinica*, 71 (5): (2022).
103. Ahmadiou, M., Adeli, H., and Adeli, A., "New diagnostic EEG markers of the Alzheimer's disease using visibility graph", *Journal Of Neural Transmission*, 117 (9): (2010).
104. Wang, J., Yang, C., Wang, R., Yu, H., Cao, Y., and Liu, J., "Functional brain networks in Alzheimer's disease: EEG analysis based on limited penetrable visibility graph and phase space method", *Physica A: Statistical Mechanics And Its Applications*, 460: (2016).
105. Zhu, G., Li, Y., and Wen, P. P., "Analysis and classification of sleep stages based on difference visibility graphs from a single-channel EEG signal", *IEEE Journal Of Biomedical And Health Informatics*, 18 (6): (2014).
106. Zheng, J., Zhang, J., Danioko, S., Yao, H., Guo, H., and Rakovski, C., "A 12-lead electrocardiogram database for arrhythmia research covering more than 10,000 patients", *Scientific Data*, 7 (1): (2020).
107. Liu, F., Liu, C., Zhao, L., Zhang, X., Wu, X., Xu, X., Liu, Y., Ma, C., Wei, S., He, Z., Li, J., and Yin Kwee, E. N., "An Open Access Database for Evaluating the Algorithms of Electrocardiogram Rhythm and Morphology Abnormality Detection", *Journal Of Medical Imaging And Health Informatics*, 8 (7): (2018).
108. Perez Alday, E. A., Gu, A., Shah, A. J., Robichaux, C., Wong, A. K. I., Liu, C., Liu, F., Rad, A. B., Elola, A., Seyedi, S., Li, Q., Sharma, A., Clifford, G. D., and Reyna, M. A., "Classification of 12-lead ECGs: The PhysioNet/Computing in Cardiology Challenge 2020", *Physiological Measurement*, 41 (12): (2020).
109. Reyna, M. A., Sadr, N., Alday, E. A. P., Gu, A., Shah, A. J., Robichaux, C., Rad, A. B., Elola, A., Seyedi, S., Ansari, S., Ghanbari, H., Li, Q., Sharma, A., and Clifford, G. D., "Will Two Do? Varying Dimensions in Electrocardiography: The PhysioNet/Computing in Cardiology Challenge 2021", *PhysioNet* (2021).
110. Pałczyński, K., Śmigiel, S., Ledziński, D., and Bujnowski, S., "Study of the Few-Shot Learning for ECG Classification Based on the PTB-XL Dataset", *Sensors*, 22 (3): (2022).
111. Sharma, K. and Eskicioglu, R., "DEEP LEARNING-BASED ECG CLASSIFICATION ON RASPBERRY PI USING A TENSORFLOWLITE MODEL BASED ON PTB-XL DATASET", *International Journal Of Artificial Intelligence And Applications (IJAIA)*, 13 (4): (2022).

112. Śmigiel, S., Pałczyński, K., and Ledziński, D., "Deep learning techniques in the classification of ecg signals using r-peak detection based on the ptb-xl dataset", *Sensors*, 21 (24): (2021).
113. Wang, J., Qiao, X., Liu, C., Wang, X., Liu, Y. Y., Yao, L., and Zhang, H., "Automated ECG classification using a non-local convolutional block attention module", *Computer Methods And Programs In Biomedicine*, 203: (2021).
114. Wu, X. Z. and Zhou, Z. H., "A unified view of multi-label performance measures", *In Proceedings of the 34th International Conference on Machine Learning*, 70: 3780–3788 (2017).
115. Anand, A., Kadian, T., Shetty, M. K., and Gupta, A., "Explainable AI decision model for ECG data of cardiac disorders", *Biomedical Signal Processing And Control*, 75: (2022).
116. Śmigiel, S., Pałczyński, K., and Ledziński, D., "ECG signalclassification using deep learningtechniques based on the PTB-XL dataset", *Entropy*, 23 (9): (2021).
117. Tao, R., Wang, L., Xiong, Y., and Zeng, Y. R., "IM-ECG: An interpretable framework for arrhythmia detection using multi-lead ECG", *Expert Systems With Applications*, 237: (2024).
118. Sharma, K. and Eskicioglu, R., "Deep Learning-based ECG Classification on Raspberry PI using a Tensorflow Lite Model based on PTB-XL Dataset", *International Journal Of Artificial Intelligence & Applications*, 13 (4): (2022).
119. Hammad, M., Chelloug, S. A., Alkanhel, R., Prakash, A. J., Muthanna, A., Elgendy, I. A., and Pławiak, P., "Automated Detection of Myocardial Infarction and Heart Conduction Disorders Based on Feature Selection and a Deep Learning Model", *Sensors*, 22 (17): 6503 (2022).
120. Sajjan M, "Learn ECG in a Day", *Jaypee Brothers Medical Pub*, (2013).
121. Goldberger, A. L., Goldberger, Z. D., and Shvilkin, Alexei., "Goldberger's Clinical Electrocardiography : A Simplified Approach", *Elsevier/Saunders*, 231 (2013).
122. A. Bayés de Luna, "Basic Electrocardiography NORMAL AND ABNORMAL ECG PATTERNS", *Wiley-Blackwell*, (2007).
123. Güven, G., "Parmak Ucu Elektrokardiyogram ve Ses Sinyali Tabanlı Biyometrik Tanıma Sistemi", *Işık Üniversitesi*, İstanbul, (2021).
124. Lawton, R., "Time Series Analysis and its Applications", *International Journal Of Forecasting*, 17 (2): (2001).
125. Lund, R., "Time Series Analysis and Its Applications: With R Examples", *Journal Of The American Statistical Association*, 102 (479): (2007).

126. Wei, W. W. S., "Multivariate Time Series Analysis and Applications", Multivariate Time Series Analysis and Applications, *Wiley*, (2019).
127. Rob J Hyndman and George, A., "Forecasting: Principles and Practice", *Principles Of Optimal Design*, (September): (2014).
128. Van den Heuvel, M. P., Bullmore, E. T., and Sporns, O., "Comparative Connectomics.", *Trends Cogn Sci.*, 20(5):345-361, 2016
129. Kivelä, M., Arenas, A., Barthelemy, M., Gleeson, J. P., Moreno, Y., and Porter, M. A., "Multilayer networks", *Journal Of Complex Networks*, 2 (3): (2014).
130. Donner, R. v., Small, M., Donges, J. F., Marwan, N., Zou, Y., Xiang, R., and Kurths, J., "Recurrence-based time series analysis by means of complex network methods", *International Journal of Bifurcation and Chaos*, 21: 1019-1046 (2011)
131. Lacasa, L., Nuñez, A., Roldán, E., Parrondo, J. M. R., and Luque, B., "Time series irreversibility: A visibility graph approach", *European Physical Journal B*, 85 (6): (2012).
132. Wang, M. and Tian, L., "From time series to complex networks: The phase space coarse graining", *Physica A: Statistical Mechanics And Its Applications*, 461: (2016).
133. Stephen, M., Gu, C., and Yang, H., "Visibility graph based time series analysis", *PLoS ONE*, 10 (11): (2015).
134. De Oliveira Campanharo, A. S. L. and Ramos, F. M., "Quantile graphs for the characterization of chaotic dynamics in time series", *2015 Third World Conference on Complex Systems (WCCS)*, Marrakech, Morocco, (2016).
135. Mutua, S., Gu, C., and Yang, H., "Visibility graphlet approach to chaotic time series", *Chaos*, 26 (5): (2016).
136. ÖZTEMEL, Prof. Dr. E., "Yapay Sinir Ağları", *Papatya Yayıncılık*, (2008).
137. Furkan Keskenler, M. and Fahri Keskenler, E., "Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi", *Takvim-I Vekayi*, 5 (5): (2017).
138. Goncalves, V., Maria, K., and da Silv, A. B. F., "Applications of Artificial Neural Networks in Chemical Problems", *Artificial Neural Networks - Architectures and Applications*, (2013).
139. Akgül, B., "Derin Öğrenme Tabanlı Yapı Elektrik Çizimi", Doktora Tezi, *Karabük Üniversitesi*, Karabük, (2021).
140. Sharma, S., Sharma, S., and Athaiya, A., "ACTIVATION FUNCTIONS IN NEURAL NETWORKS", *International Journal Of Engineering Applied Sciences And Technology*, 04 (12): (2020).

141. Liu, X., Song, L., Liu, S., and Zhang, Y., "A review of deep-learning-based medical image segmentation methods", *Sustainability (Switzerland)*, 13 (3): (2021).
142. Lundervold, A. S. and Lundervold, A., "An overview of deep learning in medical imaging focusing on MRI", *Zeitschrift für Medizinische Physik*, 29:102-127, (2019)
143. Wu, X., Sahoo, D., and Hoi, S. C. H., "Recent advances in deep learning for object detection", *Neurocomputing*, 396: (2020).
144. Krishna, M. M., Neelima, M., Harshali, M., and Rao, M. V. G., "Image classification using Deep learning", *International Journal Of Engineering And Technology(UAE)*, 7: (2018).
145. Stephen, O., Sain, M., Maduh, U. J., and Jeong, D. U., "An Efficient Deep Learning Approach to Pneumonia Classification in Healthcare", *Journal Of Healthcare Engineering*, 2019: (2019).
146. Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., and Gao, J., "Deep Learning-Based Text Classification", *ACM Computing Surveys*, 54, (2021)
147. Li, S., Song, W., Fang, L., Chen, Y., Ghamisi, P., and Benediktsson, J. A., "Deep learning for hyperspectral image classification: An overview", *IEEE Transactions On Geoscience And Remote Sensing*, 57 (9): (2019).
148. Kyathanahally, S. P., Hardeman, T., Merz, E., Bulas, T., Reyes, M., Isles, P., Pomati, F., and Baity-Jesi, M., "Deep Learning Classification of Lake Zooplankton", *Frontiers In Microbiology*, 12: (2021).
149. Han, Y., Liu, Z., Khoshelham, K., and Bai, S. H., "Quality estimation of nuts using deep learning classification of hyperspectral imagery", *Computers And Electronics In Agriculture*, 180: (2021).
150. Janiesch, C., Zschech, P., and Heinrich, K., "Machine learning and deep learning", *Electronic Markets*, 31 (3): (2021).
151. LeCun, Y., Hinton, G., and Bengio, Y., "Deep learning (2015), Y. LeCun, Y. Bengio and G. Hinton", *Nature*, 521: (2015).
152. Zhang, Y. and Ling, C., "A strategy to apply machine learning to small datasets in materials science", *Npj Computational Materials*, 4 (1): (2018).
153. Goodfellow, I., Bengio, Y., and Courville, A., "Deep Learning An MIT Press Book", *Nature*, (2016).
154. Pan, Z., Yu, W., Yi, X., Khan, A., Yuan, F., and Zheng, Y., "Recent Progress on Generative Adversarial Networks (GANs): A Survey", *IEEE Access*, 7: (2019).

155. LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P., "Gradient-based learning applied to document recognition", *Proceedings Of The IEEE*, 86 (11): 2278–2323 (1998).
156. Fukushima, K., "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position", *Biological Cybernetics*, 36 (4): (1980).
157. Le, Q. v., "Building high-level features using large scale unsupervised learning", *In Proceedings of the 29 th International Conference on Machine Learning*, Edinburgh, Scotland (2013).
158. İnternet: Raghav, P., " Understanding of Convolutional Neural Network (CNN) — Deep Learning", <https://medium.com/@RaghavPrabhu/understanding-of-convolutional-neural-network-cnn-deep-learning-99760835f148> (2019).
159. İnik, Ö. and Ülker, E., "Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri", *Gaziosmanpasa Journal Of Scientific Research*, 6 (3): (2017).
160. İnternet: Verma, S., "Understanding 1D and 3D Convolution Neural Network | Keras", <https://towardsdatascience.com/understanding-1d-and-3d-convolution-neural-network-keras-9d8f76e29610>, 2019
161. Maas, A. L., Hannun, A. Y., and Ng, A. Y., "Rectifier nonlinearities improve neural network acoustic models", *Proceedings of the 30th International Conference on Machine Learning*, (2013).
162. Albawi, S., Mohammed, T. A., and Al-Zawi, S., "Understanding of a convolutional neural network", *2017 International Conference on Engineering and Technology (ICET)*, Antalya, Turkey, 2017
163. Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K., and Ghayvat, H., "CNN Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope", *Electronics*, 10(20):2470, (2021)
164. Jiang, Z., Lai, Y., Zhang, J., Zhao, H., and Mao, Z., "Multi-factor operating condition recognition using 1D convolutional long short-term network", *Sensors (Switzerland)*, 19 (24): (2019).
165. Nandhini Abirami, R., Durai Raj Vincent, P. M., Srinivasan, K., Tariq, U., and Chang, C. Y., "Deep CNN and Deep GAN in Computational Visual Perception-Driven Image Analysis", *Complexity*, (2021)
166. Zhang, X., Wang, Y., Zhang, N., Xu, D., and Chen, B., "Research on scene classification method of high-resolution remote sensing images based on RFPNet", *Applied Sciences (Switzerland)*, 9 (10): (2019).
167. Liu, Y., Zhou, Y., Wen, S., and Tang, C., "A Strategy on Selecting Performance Metrics for Classifier Evaluation", *International Journal Of Mobile Computing And Multimedia Communications*, 6 (4): (2014).

168. Trifonova, O. P., Lokhov, P. G., and Archakov, A. I., "Metabolic profiling of human blood". *Biomed Khim.* 60(3):281-94, (2014)
169. Aksu, S., "Ses Sinyallerinin Graf Tabanlı Temsillerinin Yapay Zekâ Yöntemleri İle Sınıflandırılması", Doktora Tezi, *Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü*, Karabük, (2021).
170. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., and Farhan, L., "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions", *Journal Of Big Data*, 8 (1): (2021).
171. Krizhevsky, A., Sutskever, I., and Hinton, G. E., "ImageNet classification with deep convolutional neural networks", *Communications Of The ACM*, 60 (6): (2017).
172. He, K., Zhang, X., Ren, S., and Sun, J., "Deep residual learning for image recognition", *arXiv:1512.03385*, (2015).
173. Utomo, Y. and Kusuma, G. P., "Masked Face Recognition: Progress, Dataset, and Dataset Generation", *2021 3rd International Conference on Cybernetics and Intelligent System (ICORIS)*, Makasar, Indonesia, (2021)
174. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A., "Going deeper with convolutions", *arXiv:1409.4842*, (2015).
175. Shodieva, G. R., Ruziyeva, A. A., Nizamov, B. U., and Sharipov, A. M., "Acute myocardial infarction", *International Journal Of Current Research And Review*, 12 (14): 91–95 (2020).
176. İnternet:"Inferior Myocardial Infarction by ECG Finding", <https://www.healio.com/cardiology/learn-the-heart/ecg-review/ecg-topic-reviews-and-criteria/inferior-wall-st-elevation-mi-review>, (2020).
177. Kutluana, G. and Türker, İ., "Classification of cardiac disorders using weighted visibility graph features from ECG signals", *Biomedical Signal Processing And Control*, 87: (2024).
178. Bergillos Varela, C., "A study of visibility graphs for time series representations", BS thesis, *Universitat Politècnica de Catalunya*, (2020).
179. Zeng, M., Zhao, C. Y., and Meng, Q. H., "Detecting seizures from EEG signals using the entropy of visibility heights of hierarchical neighbors", *IEEE Access*, 7: (2019).
180. Zhang, X., Landsness, E. C., Chen, W., Miao, H., Tang, M., Brier, L. M., Culver, J. P., Lee, J. M., and Anastasio, M. A., "Automated sleep state classification of wide-field calcium imaging data via multiplex visibility graphs and deep learning", *Journal Of Neuroscience Methods*, 366: (2022).

181. Song, X. and Xiao, F., "Combining time-series evidence: A complex network model based on a visibility graph and belief entropy", *Applied Intelligence*, 52 (9): (2022).

ÖZGEÇMİŞ

Gökhan KUTLUANA ilk, orta öğrenimini Akşehir ilçesinde, yükseköğrenimini Konya ilinde tamamladı. 2004 yılında Akşehir Anadolu Lisesinden, 2008 yılında Selçuk Üniversitesi Bilgisayar Mühendisliği Bölümünden mezun oldu.

2009 yılında Bartın Üniversitesi Bilgi İşlem Dairesi Başkanlığında Programcı olarak çalışmaya başladı. 2011 yılında aynı üniversitenin Uzaktan Eğitim Araştırma ve Uygulama Merkezinde uzman olarak çalışmaya devam etti. 2013 yılından itibaren Bartın Üniversitesi Sağlık Hizmetleri Meslek Yüksekokulunda Öğretim Görevlisi olarak çalışmaya devam etmektedir.

2016 yılında yüksek lisansını Karabük Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda tamamladı. 2017 yılında başladığı doktora eğitimine Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda devam etmektedir.