

Gerçek Zamanlı Fizyolojik Sinyal Verilerinin Karşılaştırmalı Öğrenme Tekniği ile  
Kişiselleştirilmiş Anomali Tespiti

Sinem Şentepe Köse

**YÜKSEK LİSANS TEZİ**

Bilgisayar Mühendisliği Anabilim Dalı

Haziran 2024



Personalized Anomaly Detection Using Contrastive Learning Technique of Real  
Time Physiological Signal Datas

Sinem Şentepe Köse

**MASTER OF SCIENCE THESIS**

Department of Computer Engineering

June 2024

Gerçek Zamanlı Fizyolojik Sinyal Verilerinin Karşılaştırmalı Öğrenme Tekniği ile  
Kişiselleştirilmiş Anomali Tespiti

Sinem Şentepe Köse

Eskişehir Osmangazi Üniversitesi

Fen Bilimleri Enstitüsü

Lisansüstü Eğitim ve Öğretim Yönetmeliği Uyarınca

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Yazılımı Bilim Dalında

YÜKSEK LİSANS TEZİ

Olarak Hazırlanmıştır.

Danışman: Prof. Dr. Kemal Özkan

Haziran 2024

## ONAY

Bilgisayar Mühendisliđi Anabilim Dalı Yüksek Lisans öđrencisi **Sinem Őentepe Köse**'nin YÜKSEK LİSANS tezi olarak hazırladıđı “Gerçek Zamanlı Fizyolojik Sinyal Verilerinin Karşılaştırmalı Öğrenme Tekniđi ile Kişiselleştirilmiş Anomali Tespiti” başlıklı bu çalışma, jürimizce lisansüstü yönetmeliđin ilgili maddeleri uyarınca deđerlendirilerek oybirliđi ile kabul edilmiştir.

Danışman : Prof. Dr. Kemal Özkan

İkinci Danışman : -

Yüksek Lisans Tez Savunma Jürisi:

Üye: Prof. Dr. Kemal Özkan

Üye: Doç.Dr. Ahmet Arslan

Üye: Dr. Öğr. Üyesi Sinem Bozkurt Keser

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ..... tarih ve  
..... sayılı kararıyla onaylanmıştır.

Prof. Dr. ....

Enstitü Müdürü

## ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Prof. Dr. Kemal ÖZKAN danışmanlığında hazırlamış olduğum “Gerçek Zamanlı Fizyolojik Sinyal Verilerinin Karşılaştırmalı Öğrenme Tekniği ile Kişiselleştirilmiş Anomali Tespiti” başlıklı Yüksek Lisans tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallarına uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 06/06/2024

Sinem Şentepe Köse

İmza

## ÖZET

İnsanlardan alınan fizyolojik sinyaller, sağlık başta olmak üzere birçok alanda önem taşımaktadır. Kişinin kalp atış hızı, vücut sıcaklığı, kan basıncı, elektrodermal aktivite gibi bilgileri analiz edilerek kalp hastalıklarını teşhis edilebilmek, stres seviyesini belirleyebilmek, egzersiz performansını izlemek gibi birçok fayda sağlamaktadır. Teknolojinin gelişmesiyle birlikte fizyolojik sinyallerin daha kolay elde edilebilir olmasını sağlayan akıllı saatler ve bileklikler günlük yaşantımıza girmişlerdir. Bu sayede insanlar spor yaparken veya günlük hayatlarında, geliştirilen bu teknolojileri kullanarak sağlık durumlarını takip edebilmektedir. İnsan sağlığını etkileyen beslenme, fiziksel aktivite, uyku düzeni, genetik faktörler gibi unsurlardan biri de strestir. Günümüzde yaygın bir sorun haline gelen stres, sağlığımız üzerinde de ciddi etkilere sahiptir. Ayrıca vücuttaki çeşitli fizyolojik sinyaller üzerinde de stresin etkileri görülebilmektedir. Yapılan tez çalışması kapsamında da stresin fizyolojik sinyaller üzerindeki etkilerinin incelenmesi amacıyla karşılaştırmalı öğrenme modeli kullanılarak kişinin stresli olup olmadığının tespitinin yapılabilmesi hedeflenmektedir. Normal şartlar altında beklenenden farklılık gösteren, alışılmadık veya dikkat çekici olay ve durumlara anomali denmektedir. Bu nedenle çalışma kapsamında bir kişinin stresli olması anomali olarak değerlendirilmektedir. Karşılaştırmalı öğrenme, etiketlenmemiş veriler üzerinde kullanılmak üzere ortaya çıkan bir derin öğrenme yöntemidir. Zaman serisi verilerinde anomali tespiti, etiketlenme eksikliği nedeniyle genellikle sorun oluşturmaktadır. Bu sorunu çözebilmek için farklı hastalıklara sahip (obstetrik brakial pleksus yaralanması, disleksi, zihinsel engelli ve tipik olarak gelişmiş) çocuklardan alınan zaman serisi olarak tutulan kan hacmi nabızı, elektrodermal aktivite ve vücut sıcaklığı verileri ile karşılaştırmalı öğrenme modeli kullanılarak anomali tespiti yapılması hedeflenmektedir. Çalışma kapsamında ilk önce tüm veriler kullanılarak ardından kişiye özel anomali tespiti yapılmaktadır. Sonucunda ise kişiselleştirilmiş anomali tespitinin genel anomali tespitinden daha başarılı bir sonuç elde ettiği görülmektedir.

**Anahtar Kelimeler:** Karşılaştırmalı Öğrenme, Anomali Tespiti, Fizyolojik Sinyaller, Yapay Zeka

## SUMMARY

Physiological signals obtained from humans are crucial in many fields, especially in healthcare. Analyzing information such as a person's heart rate, body temperature, blood pressure, electrodermal activity, etc., can provide many benefits such as diagnosing heart diseases, determining stress levels, monitoring exercise performance, and more. With the advancement of technology, smartwatches and wristbands that make physiological signals more easily obtainable have become part of our lives. This allows individuals to track their health status while exercising or in their daily lives using these developed technologies. One of the factors affecting human health alongside nutrition, physical activity, sleep patterns, genetic factors, is stress. Stress, which has become a widespread problem today, also has serious effects on our health. Furthermore, the effects of stress can also be observed on various physiological signals in the body. As part of a thesis study, the aim is to use a contrastive learning model to determine whether a person is stressed by examining the effects of stress on physiological signals. Anomaly refers to events or situations that differ from what is normally expected, are unusual, or attention-grabbing. Therefore, within the scope of the study, a person being stressed is considered an anomaly. Contrastive learning is a deep learning method that emerged to be used on unlabeled data. Anomaly detection in time series data often poses a problem due to the lack of labeling. In order to solve this problem, the aim is to detect anomalies using a contrastive learning model with time series data of blood volume pulse, electrodermal activity, and body temperature recorded from children with different conditions (obstetric brachial plexus injury, dyslexia, intellectual disability, and typically developing). Within the study, first anomaly detection is made by using all data, and then personalized anomaly detections are detected. As a result, it is observed that personalized anomaly detection achieves more successful results than general anomaly detection.

**Keywords:** Contrastive Learning, Anomaly Detection, Physiological Signals, Artificial Intelligence

## TEŞEKKÜR

Hem yüksek lisans hem de lisans dönemlerimde her zaman yol gösteren, her anlamda yardımcı olan ve bitmek bilmeyen bir destek sunan tez danışmanım Prof. Dr. Kemal Özkan'a ve aynı şekilde tüm bu dönemler boyunca yanımda olan, devam edebilmem için güç veren can dostum Eda Tepe'ye sonsuz teşekkürlerimi sunarım.

Yaşadığım güzel veya zorlu her süreçte yanımda olan, başarılı olmam için her türlü fedakarlıkta bulunan aileme ve motivasyon kaynağım, en büyük destekçim sevgili eşim Ümit Köse'ye göstermiş oldukları sabır, anlayış ve destekleri için çok teşekkür ederim.

Bu süreçte adını sayamadığım her türlü katkı da bulunan tüm sevdiklerime minnettarım.

## İÇİNDEKİLER

	<u>Sayfa</u>
<b>ÖZET</b> .....	<b>vi</b>
<b>SUMMARY</b> .....	<b>vii</b>
<b>TEŞEKKÜR</b> .....	<b>viii</b>
<b>İÇİNDEKİLER</b> .....	<b>ix</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>xii</b>
<b>ÇİZELGELER DİZİNİ</b> .....	<b>xiii</b>
<b>SİMGELER VE KISALTMALAR DİZİNİ</b> .....	<b>xiv</b>
<b>1. GİRİŞ VE AMAÇ</b> .....	<b>1</b>
<b>2. LİTERATÜR ARAŞTIRMASI</b> .....	<b>5</b>
<b>3. TEMEL KAVRAMLAR</b> .....	<b>15</b>
3.1. Anomali Tespiti .....	15
3.2. Yapay Zeka .....	15
3.3. Makine Öğrenimi .....	16
3.3.1. Etiketli (denetimli) öğrenme (supervised learning) .....	19
3.3.2. Etiketsiz (denetimsiz) öğrenme (unsupervised learning) .....	19
3.3.3. Yarı denetimli öğrenme (semi-supervised learning) .....	20
3.3.4. Pekiştirmeli öğrenme (reinforcement learning) .....	20
3.4. Derin Öğrenme .....	20
3.5. Sinir Ağları (Neural Networks) .....	21
3.6. Evrişimsel Sinir Ağları (Convolutional Neural Networks-CNN) .....	22
3.7. Zamansal Evrişimsel Ağlar (Temporal Convolutional Networks-TCN) .....	24
3.8. Veri Artırma (Data Augmentation) .....	25
3.9. Kayan Pencere Tekniği (Sliding Window) .....	25
<b>4. MATERYAL VE YÖNTEM</b> .....	<b>27</b>

## İÇİNDEKİLER

### Sayfa

4.1. Karşılaştırmalı Öğrenme (Contrastive Learning) .....	27
4.1.1. Denetimli karşılaştırmalı öğrenme (SCL) .....	29
4.1.2. Kendi kendine denetimli karşılaştırmalı öğrenme (SSCL).....	29
4.2. Veri Seti.....	31
4.3. Zaman Serisi Anomali Tespiti için Karşılaştırmalı Öğrenme Yöntemi (CL-TAD). 33	
4.3.1. Temsil öğrenme aşaması .....	34
4.3.1.1. <u>Pozitif örnek oluşturulması</u> .....	35
4.3.1.2. <u>Karşılaştırmalı öğrenme tabanlı temsil öğrenmesi</u> .....	36
4.3.2. Anomali tespiti aşaması.....	37
4.4. Füzyon (Fusion).....	39
4.4.1. Veri seviyesi füzyon (data level fusion).....	39
4.4.2. Özellik seviyesi füzyon (feature level fusion).....	40
4.4.3. Karar tabanlı füzyon (desicion level fusion) .....	41
4.4.4. Hibrit füzyon (hybrid fusion) .....	41
4.5. Füzyon ve CL-TAD.....	42
<b>5. BULGULAR VE TARTIŞMA .....</b>	<b>43</b>
<b>6. SONUÇ VE ÖNERİLER .....</b>	<b>51</b>
<b>KAYNAKLAR DİZİNİ.....</b>	<b>53</b>

## ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
2.1. Önerilen sistem mimarisi .....	6
2.2. CARLA mimarisi .....	9
2.3. Çoklu görünümlü yüz ifadelerinin karşılaştırmalı öğrenimi modelinin ön eğitimi.....	10
2.4. MoCo yapısı .....	11
2.5. COCA modelinin mimarisi.....	13
2.6. EKG anomali tespiti modeli .....	14
3.1. Denetimli öğrenme modeli .....	19
3.2. Makine öğrenmesi ve derin öğrenme farkı.....	21
3.3. Yapay sinir ağı bileşenleri .....	22
3.4. CNN mimarisi .....	23
3.5. TCN mimarisi .....	24
3.6. Veri artırımı örneği.....	25
3.7. Sabit boyutlu kayan pencere tekniği örneği .....	26
4.1. Karşılaştırmalı öğrenme yönteminin arkasındaki yapı.....	28
4.2. Karşılaştırmalı öğrenme mimarisi .....	28
4.3. Denetimli ve kendi kendine denetimli karşılaştırmalı öğrenme.....	30
4.4. SimCLR mimarisi.....	31
4.5. AKTIVES veri toplama süreci .....	32
4.6. CL-TAD modeli .....	33
4.7. X zaman serisi dizisinden, W alt dizi örneklerinin oluşturulması .....	34

## ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
4.8. Her biri 5 uzunluğundaki alt dizi örneğinden, 10'luk maskelenmiş bir yığın oluşturma süreci .....	35
4.9. Yeniden yapılandırma tabanlı kodlayıcı-kod çözücü modülü.....	36
4.10. Karşılaştırmalı öğrenme tabanlı temsil öğrenmesi mimarisi.....	37
4.11. Temsil oluşturma ve anomali skor hesaplaması.....	38
4.12. Nokta ayarlama tekniği.....	39
4.13. Veri seviyesi füzyon modeli.....	40
4.14. Özellik seviyesi füzyon modeli .....	40
4.15. Karar tabanlı füzyon modeli .....	41
4.16. Hibrit füzyon modeli .....	42
5.1. C01 BVP için gerçek ve tahmin edilen etiket karşılaştırılması.....	45
5.2. C01 EDA için gerçek ve tahmin edilen etiket karşılaştırılması .....	45
5.3. C01 ST için gerçek ve tahmin edilen etiket karşılaştırılması .....	46
5.4. C01 füzyon işlemi sonrası gerçek ve tahmin edilen etiket karşılaştırılması.....	48
5.5. C10 füzyon işlemi sonrası gerçek ve tahmin edilen etiket karşılaştırılması.....	49

## ÇİZELGELER DİZİNİ

### Cizelge

### Sayfa

3.1 Karmaşıklık matrisi .....	17
5.1. Genel BVP, EDA ve ST doğruluk oranları .....	44
5.2. Kişiselleştirilmiş BVP, EDA ve ST doğruluk oranları.....	46
5.3. Füzyon sonrası doğruluk oranları .....	49



## SİMGELER VE KISALTMALAR DİZİNİ

Kisaltmalar	Açıklama
WHO	Dünya Sağlık Örgütü (World Health Organization)
CL	Karşılaştırmalı Öğrenme (Contrastive Learning)
BVP	Kan Hacmi Nabzı (Blood Volume Pulse)
EDA	Elektrodermal Aktivite (Electrodermal Activity)
ST	Deri Sıcaklığı (Skin Temperature)
MASC	Çocuklara Yönelik Çok Boyutlu Kaygı Ölçeği (Multidimensionak Anxiety Scale for Children)
CDI	Çocuklarda Depresyon Envanteri (Children's Depression Inventory)
STAIC	Çocuklara Yönelik Stabil-Sürekli Kaygı Envanteri (State-Trait Anxiety Inventory for Children)
SCL	Denetimli Karşılaştırmalı Öğrenme (Supervised Contrastive Learning)
SimCLR	Temsillerin Basit Karşılaştırmalı Öğrenimi (Simple Contrastive Learning of Representations)
SSCL	Kendi Kendine Denetimli Karşılaştırmalı Öğrenme (Self Supervised Contrastive Learning)
CL-TAD	Zaman Serisi Anomali Tespiti için Karşılaştırmalı Öğrenme Yöntemi (Contrastive Learning based method for Times series Anomaly Detection)
CNN	Evrişimsel Sinir Ağları
CSV	Virgülle Ayrılmış Değerler (Comma Separated Values)

## 1. GİRİŞ VE AMAÇ

İnsan sađlığını etkileyen faktörlere; beslenme, uyku düzeni, fiziksel aktiviteler, genetik aktarımlar gibi unsurlar örnek olarak verilebilmektedir. Bu faktörlere ek olarak streste sađlık açısından önemli bir faktördür. Stres, tüm canlılar özelinde günlük yaşantımızda sıkça karşılaştığımız bir kavram haline gelmektedir. Bu kavram, birçok alanda kullanılmakta ve çeşitli şekillerde tanımlanmaktadır. Stres, zor bir durumdan kaynaklanan kaygı veya zihinsel gerginlik olarak tanımlanabilmektedir (WHO, 2024). Genellikle, sađlık ve yaşam kalitesi üzerindeki olumsuz etkileri hakkında durulmaktadır. Ancak Selye (1950), stres hayatın baharatıdır, stresin olmaması ölümdür şeklinde belirtmektedir. Bu nedenle, stresin hayatımız üzerindeki olumlu etkilere sahip olabileceđi de düşünölmektedir.

Günümüzde geliştirilmekte olan akıllı saatler, bileklikler ve birçok teknolojik aletler sayesinde fizyolojik sinyallere daha rahat ulaşılabilir. Fizyolojik sinyaller, elektroensefalografi (EEG), sıcaklık (T), elektrokardiyogram (EKG), elektromiyografi (EMG), galvanik cilt tepkisi (GSR), solunum (RSP) vb. gibi veriler içerir (Shu vd., 2018). Sađlık alanında kullanılan bu fizyolojik sinyallere daha kolay ulaşım, hastalıklara karşı daha hızlı önlemler alınabilmesine olanak sađlamaktadır. Bu sayede erken tedavi ile hastalıkların ilerlemesinin önüne geçebilmektedir.

Normal koşullar altında anomali durumunun ortaya çıkmaması beklenmektedir. Sađlık alanında, tıbbi bir test sonucunda bulunan deđerlerin normal aralık içerisinde bulunmaması anomali durumuna örnek olarak verilebilmektedir. Bir kişinin genel yaşamı boyunca stressiz ve dođal olması beklenmektedir. Bu nedenle stres altındaki bir kişi anomali olarak deđerlendirilmektedir. Ortaya çıkan anomali durumlarının sebeplerinin tespiti için birçok yöntem geliştirilmekte ve kullanılmaktadır.

Günlük hayatta yaşanan birçok zorluk insan psikolojisini fazlasıyla etkilemekte ve strese neden olmaktadır. Böyle zamanlarda bazen birey stresli olduğunu fark edememektedir. Teknolojinin gelişimi ile ortaya çıkan giyilebilir ürünler kullanılarak çeşitli fizyolojik sinyaller elde edilebilmekte ve bu veriler kolay bir şekilde ulaşılabilir olmaktadır. Bu nedenle bu verilerin işlenebilmesi ve bireylerin sağlık durumları hakkında tespit yapılabilmesi de kolay olmaktadır. Daha rahat elde edilebilen bu fizyolojik sinyaller kullanılarak, tez kapsamında bireye gerçek zamanlı olacak şekilde stresli olup olmadığı bilgisinin verilebilmesi amaçlanmaktadır. Bu kapsamda stresli durumlar anomali olarak değerlendirilmekte ve gerçek zamanlı fizyolojik sinyal verileri kullanılarak kişiselleştirilmiş anomali tespiti yapılması hedeflenmektedir.

Hedeflenen durumlar için tez kapsamında önerilen yöntem, anlık olarak bireyin stres durumu ile ilgili bilgilendirme sağlayabilecek şekilde geliştirilmektedir. Bu sayede sağlık kuruluşlarına gitmeden daha hızlı şekilde bireyin kendi durumu hakkında bilgi alabilmesine olanak sağlamaktadır.

Anomali tespitinin yapılabilmesi için uygulanan yöntem, bireylerden alınan zaman serisi kan basıncı hacmi (BVP), deri sıcaklığı (ST) ve elektrodermal aktivite (EDA) fizyolojik sinyallerini içeren veri seti kullanılmaktadır. Fizyolojik sinyallerin normal ve anormal olarak değerlendirilme durumu kişiye göre değişebilmektedir. Bu nedenle her kişi özelinde anomali tespitinin yapılması üzerine odaklanan çalışmanın daha başarılı olacağına inanılmaktadır. Bu kapsamda da her birey üzerinden alınan veriler ayrı ayrı değerlendirilerek anomali tespiti yapılmaktadır.

Bir bebeğin hayata gelmesi ile birlikte hiçbir bilgi birikimine sahip olmadan inceleyerek, aradaki farkları gözlemleyerek öğrenmesi gibi bir bakış açısıyla ortaya çıkan karşılaştırmalı öğrenme yöntemi, etiketlenmemiş veriler içeren birçok alanda çalışabilmektedir. Zaman serisi verilerinde genellikle etiketlenme eksikliği bulunmaktadır. Bu nedenle etiketlenmemiş olan zaman serisi verileri üzerinde anomali tespitinin yapılması

da zorlaşmaktadır. Yapılan tez çalışma kapsamında önerilen Karşılaştırmalı Öğrenme yöntemi, bu problemin önüne geçebilmek avantaj sağlamaktadır.

Sağlık alanında geleneksel tedavi yöntemlerine ek olarak, günümüzde sağlık teknolojilerinin gelişmesi ile birlikte oyun tabanlı yeni çözümler ortaya çıkmaktadır. Oyunlar eğlenerek öğrenmeye ve gelişmeye olanak sağlamaktadır. Bunun yanı sıra bireyin sağlığı için yapması gerekenleri daha kolay anlamasına, motivasyonun artmasına ve daha bilinçli olmasına da yardımcı olmaktadır. Tez çalışması kapsamında kullanılan veri seti de oyun tabanlı bir uygulama sırasında alınan verileri içermektedir. Bu sayede oyun oynarken kişiselleştirilmiş stres tespiti yapılabilmesine olanak sağlamakta ve bu süreçte hem bireye hem de sağlığını takip eden yetkililere bilgilendirme yapılabilmektedir.

Çalışma genel olarak değerlendirildiğinde anomali tespiti üzerinde yoğunlaşmaktadır. Bu nedenle sunulan yöntem stres dışındaki farklı sağlık problemleri içinde anomali değerlendirmelerinin yolunu açabilmektedir. Stres dışında farklı alanlarda da anomali olarak değerlendirilebilecek durumlar için bu yöntemin kullanılabilir olması bir avantaj sağlamaktadır. Çalışmada kullanılan yöntem hangi alanda kullanılırsa kullanılsın, yapmış olduğu anomali tespiti sayesinde, kullanıcıya yapacak olduğu bilgilendirme ile birlikte bireyin daha bilinçli olmasına olanak sağlayacağı düşünülmektedir.

Yapılan çalışma ile birlikte elde edilen kazanımlar aşağıdaki gibidir:

- Karşılaştırmalı öğrenme yönteminin etiketlenmemiş zaman serisi içeren veriler üzerinde de başarılı olduğu gözlemlenmektedir.
- Karşılaştırmalı öğrenmenin, zaman serisi verilerindeki etiketlenme eksikliğine çözüm olarak sunulabileceği görülmektedir.

- Çalışma kapsamında elde edilen sonuçlar, fizyolojik sinyaller kullanılarak yapılan anomali tespitinin kişiselleştirilmesinin daha doğru bir yaklaşım olduğunu göstermektedir.
- Karşılaştırmalı öğrenme yöntemine ek, füzyon işleminin kullanılarak farklı fizyolojik sinyallerin bir arada değerlendirilmesi de güvenilir sonuçlar vermektedir.
- Hali hazırda bulunan karşılaştırmalı öğrenme modellerinin geliştiği ve daha da geliştirilebileceği görülmektedir.
- Literatürde farklı fizyolojik sinyallerin bir arada kullanılarak karşılaştırmalı öğrenme yöntemi ile stres tespitinin yapıldığı görülmemiş, bu çalışma ile birlikte gelecek çalışmalara örnek olmaktadır.
- Bireyin akıllı saati üzerinden alınan fizyolojik sinyallerin belirli bir süre boyunca o iki özelinde eğitilip ardından anomali tespitinin yapılabilmesine olanak sağlanmaktadır.

## 2. LİTERATÜR ARAŞTIRMASI

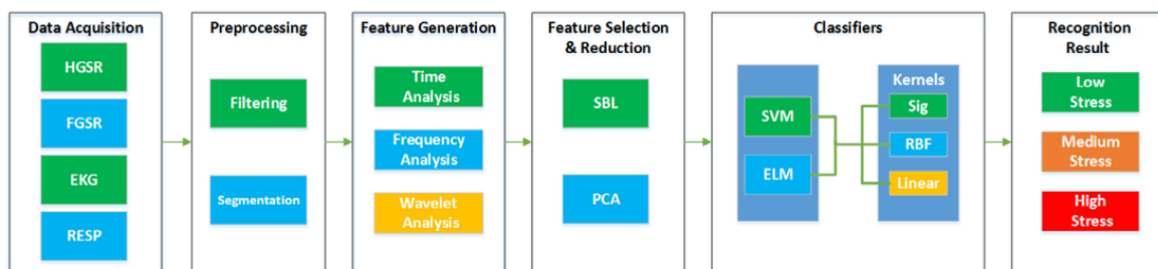
Beklenildiği gibi ya da normal olmayan durumlara anomali denmektedir. Anomali tespiti için uzun yıllardır farklı alanlar ve farklı durumlar için çeşitli çalışmalar yapılmaktadır. Yapılan çalışmalar ile genel amaç sorunu çözebilmek, gözden kaçan, fark edilemeyen durumları tespit edip önlem alabilmektir. Bu sayede hangi alanda olursa olsun kalitenin artırılması, hızlı çözümler sağlanabilmesi amaçlanmaktadır.

Sağlık alanında yapılan çalışmalar geniş bir yelpaze içermektedir. Günümüzde insan psikolojisi, motivasyonu da diğer sağlık durumları gibi önemli bir konuma gelmektedir. Yaşam kalitesinin artırılması ile birçok hastalığın önüne geçilebilmekte ayrıca belirli bir hastalığa sahip olan bireyin iyileşme sürecini de kısalttığına inanılmaktadır. Bu nedenle önemli olarak değerlendirilen insan psikolojisini öğrenebilmek ve iyileştirebilmek için birçok çalışma ve uygulama bulunmaktadır. Geçmişte daha çok sokakta oynanan oyunlar, günümüzde ise daha çok teknolojinin gelişmesi ile birlikte ortaya çıkan oyunlar her yaşta insana hitap etmektedir. Eğlenmek amacıyla ortaya çıkan oyunlar psikolojik ve fizyolojik birçok etkene sahiptir.

Yaşam kalitesini arttırmak ve yaşlılar için düşme ve hastalıkların sonuçlarını azaltmak amacıyla Han vd. (2018) sağlık verilerini toplayarak ve derin öğrenme algoritmalarını kullanarak temassız sensörler ile sistem oluşturmaktadırlar. Verileri toplayabilmek için mikrodalga sensörlerini ve kamera kullanmaktadırlar. Çalışma kapsamında her 10 saniyede 500 bileşenden oluşan veri toplanmıştır. Çalışmanın amacı anormal aktivite ve anormal verileri tespit edebilmektir. Anormal aktivite, aşırı uyku gibi aktivitelerin zamanla değişmesinin anormal olduğu anlamına gelmektedir. Anormal veriler, verilerin önceki halinden tamamen farklı olduğu anlamına gelmektedir. Benimsemiş oldukları yaklaşımlar, anormal aktivite için ham verilere dayalı ve anormal veri için spektrograma dayalıdır. Spektrogram, zamanla değişen sinyal frekanslarının spektrumunun görsel bir temsilidir. Ham veriler için Evrimsel Sinir Ağları (ESA, Convolutonal Neural

Network-CNN) ve Destek Vektör Makinesi (DVM, Support Vector Machine-SVM), spektrograma dayalı veriler için Yinelemeli Sinir Ağı (YSA, Recurrent Neural Network-RNN) kullanılmaktadır. Her iki yaklaşımın performansının da başarılı olduğunu kanıtlamaktadırlar.

Chen vd. (2017) fizyolojik sinyalleri kullanarak bir kişinin araç kullanırken stresini tespit edebilmek amacıyla bir çalışma yapmaktadır. Bu amaç doğrultusunda öncelikle elektrokardiyogram, galvanik deri tepkisi ve solunum gibi verileri içeren fizyolojik sinyalleri 14 sürüş boyunca kaydetmektedirler. Bu bilgiler ile sürüş stresini tespit edebilmek için çoklu model özellik çıkarımı analizi ve çekirdek tabanlı (kernel-based) sınıflandırıcılar kullanılmaktadır. Şekil 2.1'de de gösterildiği gibi önerilen yöntem, seyrek bayesian öğrenme yöntemini en uygun veri özelliklerini seçmek için ve Temel Bileşen Analizini (TBA, Principal Component Analysis-PCA) özellik boyutunu azaltmak amacıyla kullanarak zaman, spektral ve dalgacık alanında özellik çıkarımı yapmaktadırlar. Stres algılama için SVM ve Aşırı Öğrenme Makinesi (AÖM, Extreme Learning Machine-ELM) gibi çekirdek tabanlı sınıflandırıcıları kullanarak farklı sürüş stres seviyelerini sınıflandırmaktadırlar ve önerilen sistem %89 üzerinde başarı göstermektedir.



Şekil 2.1. Önerilen sistem mimarisi (Chen vd., 2017)

İnsan sağlığını iyileştirmek amacıyla ortaya çıkan oyun tabanlı uygulamalar günümüzde yaygınlaşmaktadır. González-González vd. (2021) tarafından yapılan çalışmanın amacı da çocuklarda obezite tedavisine yardımcı olmaktır. Çalışma kapsamında kinect sensörünü ve biyometrik sensörleri kullanarak aktif oyunlara dayalı iki çözüm sunulmaktadır. Kalp atış hızı kontrollü bir yapıyı biyometrik sensörler ve Kinect sensörünü

kullanarak oluşturmaktadır. Oluşturulan oyun web tabanlıdır ve çocukların evde de kullanabilmesine olanak sağlamaktadır. Aktif video oyunlarının motive edici olduğunu savunan çalışma, sonucunda yapılan anket sonrasında ortaya çıkan memnuniyet oranı ile de başarılı olduğunu kanıtlamaktadır.

Nawaz ve Ahmed (2021) fizyolojik sinyallerin incelenmesinin, hastalığın zamanından önce tahmin edilmesine yardımcı olacağını ve bu nedenle bu verilerin hayati önem taşıdığını belirtmektedir. Bu nedenle çalışma kapsamında biyomedikal sensörler ile insanlardan alınan zaman serisi fizyolojik sinyal verilerini toplayıp, işleyip, analiz etmektedirler. Nesnelere interneti tabanlı bir sağlık sistemi uygulaması kurarak bireye, herhangi bir anomali olması durumunda uyarı vermekte ve anormalliğin türünü sınıflandırarak bilgi vermeyi amaçlamaktadırlar. Elektrokardiyogram (EKG), kalp hızı değişkenliği (HRV) ve elektromiyogram (EMG) için bir boyutlu CNN kullanarak eğitim süreci gerçekleştirilmektedir. Sınıflandırıcı da kullanılan model 256'lık bir Uzun Kısa Süreli Bellek (UKSB, Long Short-Term Memory-LSTM) katmanı ve ardından 0,2'lik bir seyreltme katmanından oluşmaktadır. Anomali tespit edilmesi halinde çok sınıflı karar destek makinesi kullanarak sınıflandırılmaktadır. Gerçek zamanlı sinyallerin anomali tespitinde %98 başarı elde etmektedirler.

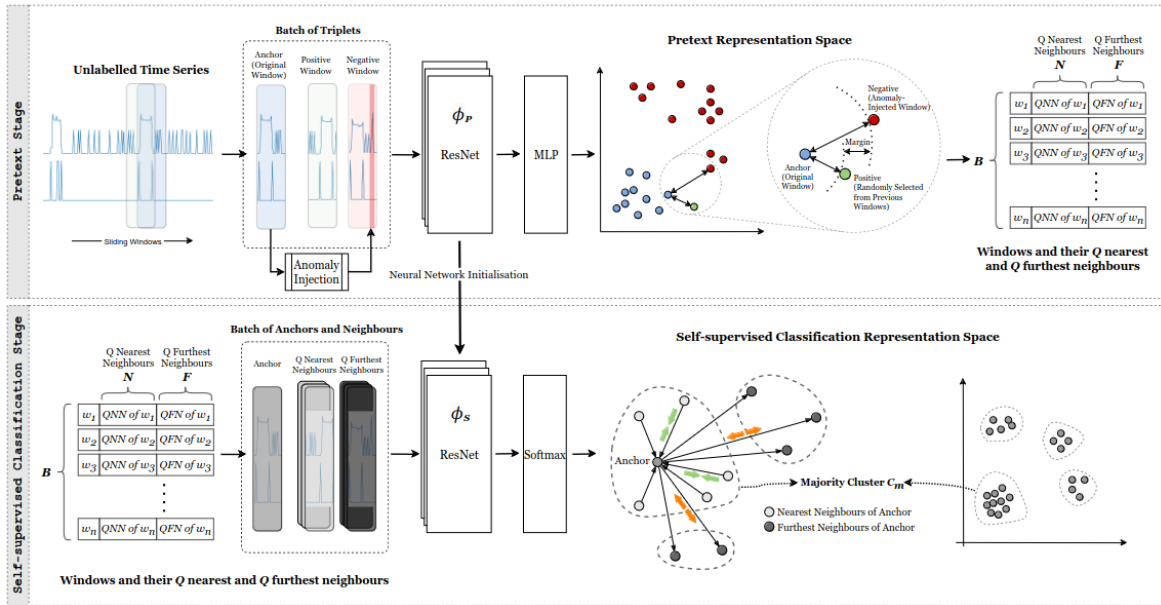
Liu (2021) tarafından yapılan çalışmada zihinsel aktivitenin göstergesinin ruh sağlığı olduğu ve ruh sağlığının insan vücudunu bütünüyle etkilediği vurgulanmaktadır. Bu nedenle insan ruh sağlığı durumunu değerlendirebilmek için fizyolojik sinyalleri kullanan bir tespit modeli geliştirilmektedir. Çalışma kapsamında öncelikle kayan pencere (sliding window) yöntemi kullanılmaktadır. Bu yöntem sayesinde fizyolojik sinyal özelliği çıkarılmakta ve veri seti ile karşılık gelen süre kayan pencere yöntemiyle birkaç parçaya bölünmektedir. Ardından istatistikteki ayrık trend analizi kullanılarak EKG sinyallerinin değişim özellikleri analiz edilerek, fizyoloji sinyallerinin istatistiksel indeksleri hesaplanmaktadır. SVM kullanılarak da zihinsel duruma ait fizyolojik sinyaller sınıflandırılmaktadır. Çalışma sonucunda önerilen yöntemin hatasının küçük olduğu ve zaman tüketiminin kısa olduğu belirtilmektedir. Buna rağmen fizyolojik sinyallerin örnek çıkarımı sınırlı olduğuna

değinererek, örnek sayısının arttırılarak daha doğru sonuçlar elde edilebileceğini savunmaktadır.

Knox vd. (2011) tarafından yapılan çalışma kapsamında rahatlamayı öğretmek ve uygulamak amacıyla oyun tabanlı çözüm sunulmaktadır. Sunulan çözüm için çalışma, anksiyete tedavisi gören 9 ile 17 yaş arasındaki 24 çocuk ve ergenler için uygulanmaktadır. Çocuklara özel tasarlanmış bir video oyunu kullanılarak biyolojik geri bildirim sağlanmakta ve bu oyunun anksiyete ile depresyon semptomları üzerindeki etkisi değerlendirilmektedir. Freeze-Framer 2.0 ve Journey to Wild Divine: The Passage yazılım programları kullanılarak kalp atış hızı ve cilt iletkenlik seviyesindeki değişiklikler kaydedilmektedir. Cilt iletkenliği ölçümü ter bezlerinin aktivitesinin hesaplanmasıdır. Terlemede artışın olması hem endişe hem de heyecanda artık anlamına gelebilmektedir. Bu oyunlar, kişinin ekranda beliren çayırı renklendirmek, gökkuşağı yapmak, sıcak hava balonunda yüzmek, ateş yakmak, duvar inşa etmek, ok atmak gibi faaliyetlerde bulunmasını sağlamakta ayrıca, rahatlamaya yardımcı olabilmek için görüntü ve ses içermektedir. Kişi rahatladıkça kalp atımları arasındaki fark miktarı artmakta, cilt iletkenlik seviyesi de azalmaktadır. Bu görevlerin yapılabilmesi için de kullanıcının rahatlaması beklenmektedir, diğer türlü görevler başarı ile gerçekleştirilememektedir. Uygulama öncesinde ve sonrasında katılımcıların Çocuklar için Durum-Sürekli Kaygı Envanteri (ÇDSKE, State-Trait Anxiety Inventory for Children-STAIC), Çok Boyutlu Çocuk Anksiyete Ölçeği (ÇBÇAÖ, Multidimensional Anxiety Scale for Children-MASC) ve Çocuklar için Depresyon Belirtileri Envanteri (ÇDBE, Children's Depression Inventory-CDI) metriklerini tamamlaması istenmektedir. MASC çocuklarda anksiyete semptomlarını değerlendirmektedir. CDI'den alınan puanlar depresyonun varlığını veya yokluğunu önermek amacıyla kullanılmaktadır. STAIC ise geçici bir duygu olan kaygı ile daha istikrarlı kaygı veya kaygıya yatkınlık arasında ayırım yapmak için kullanılmaktadır. Oyun sonrasında tekrar uygulanan STAIC, MASC ve CDI metrik değerlendirmelerinde iyileşmeler gözlenmektedir.

Darban vd. (2023) CARLA adını verdikleri kendi kendine denetimli karşılaştırmalı öğrenme yöntemi kullanarak zaman serisi verilerindeki anomali tespiti yapan modeli tanıtmaktadır. Hem tek boyutlu hem de çok boyutlu veriler üzerinde çalışabilecek şekilde önerdikleri model, anomali tespitinin performansını artırabilmek amacıyla iki aşamadan oluşmaktadır. Şekil 2.2'de de görüldüğü üzere bunlardan biri öz metin aşaması diğeri ise

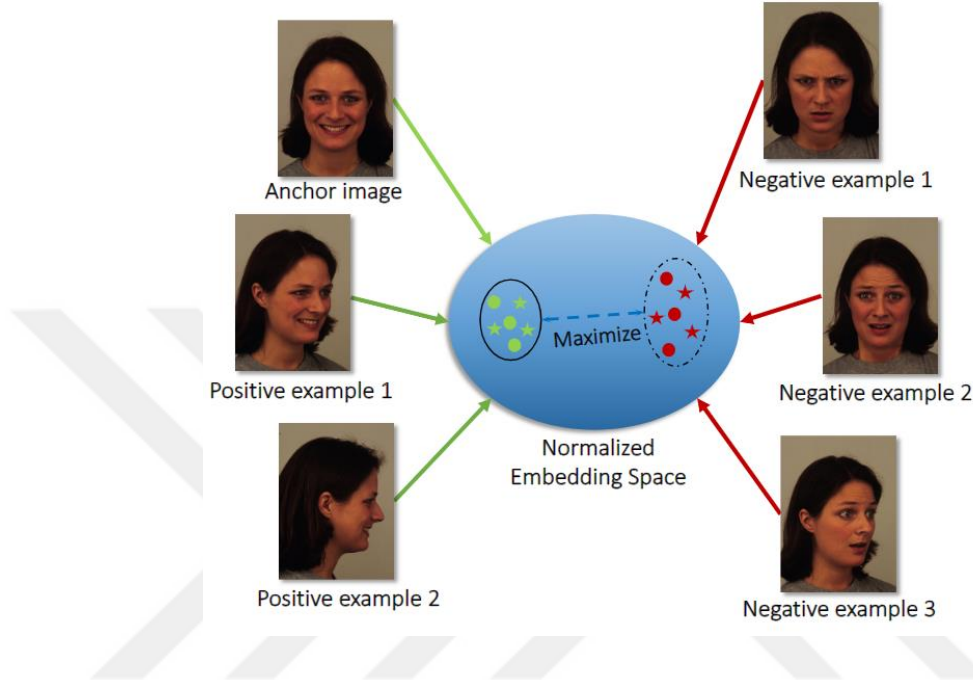
kendi kendine denetimli sınıflandırma aşamasıdır. Öz metin aşamasında veri artırımı için anomali enjeksiyon tekniklerini kullanmaktadır. Anomali enjeksiyon teknikleri olarak ani zirveler gibi nokta anomalilerini ve beklenmedik desen değişiklikleri gibi alt dizileri içermektedir. Bu aşama ile çeşitli anomali türleri arasında genelleme yapabilme yeteneğinin güçlenmesi hedeflenmektedir. Denetimli sınıflandırma aşamasında ise öğrenilen temsilleri entegre ederek, artırılan orijinal veriler ile en yakın komşuları arasındaki benzerliği maksimize etmektedir. Veri artırımına uğrayan orijinal veriler ile en uzak komşuları arasındaki benzerliği minimize etmektedir. Önerilen yöntemin gelecekteki modellerin performansını değerlendirmek için bir temel oluşturduğunu savunmaktadırlar.



Şekil 2.2. CARLA mimarisi (Darban vd., 2023)

Roy ve Etemad (2021) yüz ifadelerini tanıyan sistemlerin yandan bir görüntü ile karşılaşması durumunda genelde performans düşüklüğüne değinmektedir. Bu nedenle ortaya çıkardıkları CL-Mex (Contrastive Learning of Multi-view facial Expressions) modeli ile bu durumun önüne geçebilmeyi hedeflemektedirler. İki aşamalı eğitim süreci olan bu model öncelikle aynı ifadeye sahip farklı görünüşler için kendi kendini denetleyen ön öğrenme gerçekleştirmektedir. Bu aşamada Şekil 2.3'te gösterildiği gibi aynı ifadedeki farklı görüş açısındaki verilerin birlikte gruplanması sağlanmaktadır. Böylelikle yan görünümdeki veriler önden görünüm içeren verilerin daha etkili temsilleri ile güçlendirilmesini sağlayan

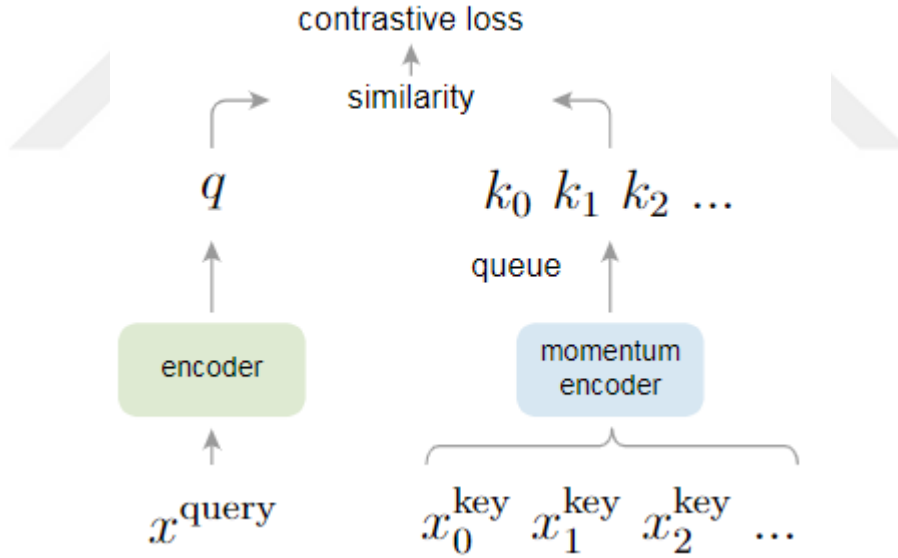
kayıp fonksiyonları daha iyi performans elde etmesini amaçlamaktadır. İlk eğitim aşamasından sonra denetimli bir ortamda etiketli verilerle model ayarlanmaktadır. KDEF ve DDCF veri setlerinde %94 üzerinde başarı elde etmektedirler.



Şekil 2.3. Çoklu görünümlü yüz ifadelerinin karşılaştırmalı öğrenimi modelinin ön eğitimi (Roy ve Etemad, 2021)

Facebook yapay zeka araştırma (FAIR) ekibinde olan Chen vd. (2020) kendi kendine denetimli karşılaştırmalı öğrenme yöntemi olan MoCo v2'yi sunmuşlardır. Bu yöntem yine FAIR ekibindeki He vd. (2020) tarafından geliştirilen Momentum Contrast (MK, Momentum Contrast-MoCo) metodunun geliştirilmiş yeni bir versiyonudur. Temsillerin Basit Karşılaştırmalı Öğrenimi (TBKÖ, Simple Contrastive Learning of Representations-SimCLR) yöntemindeki projeksiyon başlığı ve daha güçlü veri artırma tasarımlarını MoCo modeline entegre etmektedirler. Projeksiyon başlığı aşamasında artık tek katmanlı doğrusal başlık yerine İki Katmanlı Algılayıcı (İKA, Multi Layer Perceptron-MLP) kullanılmaktadır. Ayrıca MoCo ve MoCo v2 grup normalizasyonu kullanmasına rağmen MoCo v2'de ayarlamalar denetimsiz öğrenme yöntemine uygun şekilde daha fazla yapılmaktadır. Böylece eğitim için büyük verilere ihtiyaç duyulmaması amaçlanmaktadır.

MoCo'nun mimarisinde Şekil 2.4'te görüldüğü üzere anahtar, sorgular, kodlayıcı, momentum kodlayıcı ve karşılaştırmalı kayıp bileşenleri bulunmaktadır. Sorgu görüntü olarak düşünülebilir ve bu kısım kodlayıcıdan geçmektedir. Anahtar olarak adlandırılan kısım ise bir görüntünün veri artırımı yoluyla oluşan halidir ve momentum kodlayıcıdan geçmektedir. Sorgu ve anahtarlar bilgileri pozitif olarak, diğer bilgiler ise negatif olarak kabul edilmektedir. Kodlayıcı kısmı için ResNet kullanılmaktadır ancak farklı mimarilerde kullanılabilir. Özellik kuyruğu çok büyük olduğu için geribildirim yöntemi ile anahtar kodlayıcının oluşturulması sorun oluşturmaktadır. Bu sorunu çözebilmek adına momentum kodlayıcısı önermektedirler. Karşılaştırmalı kayıp orijinal veri ile bu veriye karşılık pozitif ve negatif anahtarlar arasındaki benzerliği ölçmektedir. Önerilen yöntemin performansı SimCLR ile karşılaştırılmakta ve buna göre SimCLR'den %5.6 daha doğruluk oranına sahip olduğu görülmektedir.

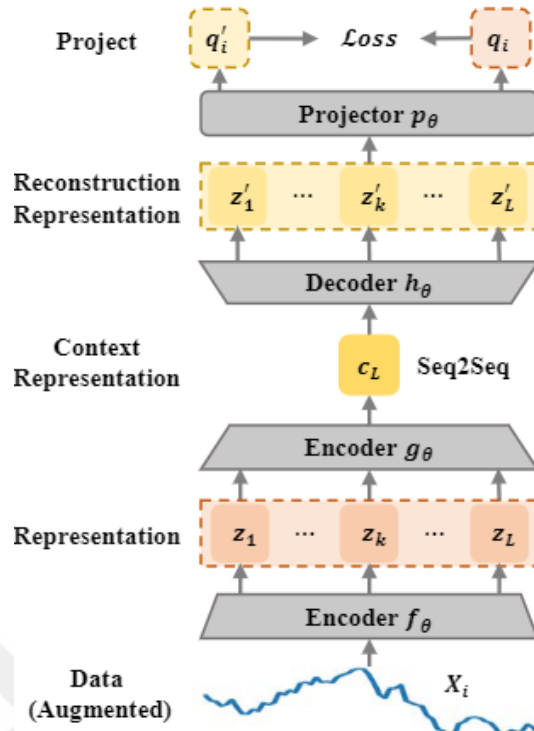


Şekil 2.4. MoCo yapısı (He vd., 2020)

Nesne tespit edebilmek için Xie vd. (2021) tarafından ortaya atılan DetCo modeli kendi kendine denetimsiz öğrenme yöntemlerinden biri olan ve özellikle görüntü sınıflandırma için kullanılan momentum kontrast v2 (MoCo v2) temel alarak çalışmaktadır. Çeşitli veri setlerinde test edilen DetCo modelinin MoCo v2'den farklarından biri çok seviyeli süpervizyondur. Bu sayede çeşitli aşamalardaki özellikler ayırt edici olmaktadır. Bir

diđeri ise küresel ve yerel karşılaştırmalı öğrenmesidir. Bu aşamada ilk olarak girdi 9 yerel bilgiye dönüştürölmek için jigsaw veri artırımı gerçekleştirilmektedir. Bu bilgiler kodlayıcıdan geçirilip 9 yerel özellik temsili elde edilmektedir. Ardından bu özellikler MLP ile birleştirilerek küresel özellik temsili oluşturulmaktadır. Böylelikle de hem küresel hem de yerel özellik temsilleri güçlendirilmektedir. Genel olarak sunmuş oldukları model bu iki farklılık sayesinde nesne tespitinde başarılı bir performans ortaya koymaktadır.

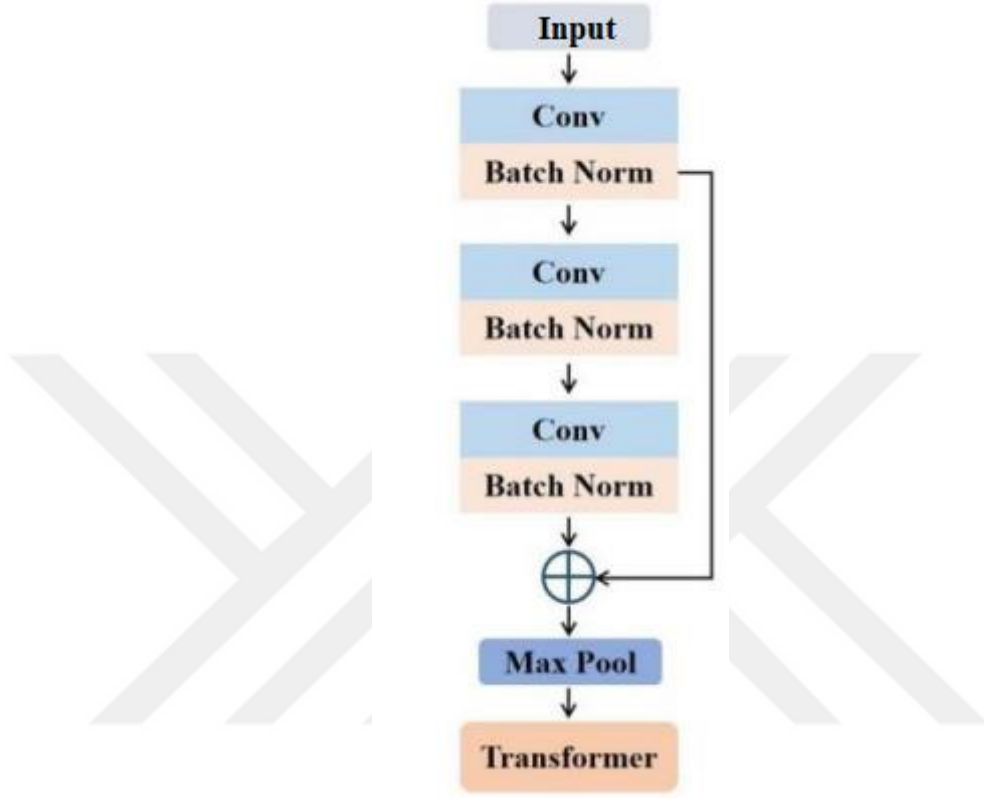
Wang vd. (2023) tarafından tanımlan ve Şekil 2.5'te gösterilen Karşılaştırmalı Tek Sınıflı Anomali Tespiti (KTSAT, Contrastive One-Class Anomaly detection-COCA) modeli zaman serisi verilerinin artışı ve etiketlerinin bulunmaması gibi sorunların üstesinden gelebilmek amacıyla geliştirilmiştir. İlk olarak orijinal eğitim verilerini arttırarak, anormallikleri normal izole etmektedir. Ardından arttırılan bu zaman serisi verileri, Çok Katmanlı Zamansal Evrişimsel Sinir Ađı (ÇKZESA, Multi-Layer Temporal Convolution Neural Network-MLTCN) ile kodlanmaktadır. Sonrasında zamansal bađlılıkları öğrenbilmesi için Seq2Seq modeline yerleştirilmektedir. Son aşamada ise pozitif çiftler, sırasıyla projeksiyonlarını elde etmek için öğrenilebilir doğrusal olmayan bir projeksiyon katmanına beslenmektedir. Modeli eğitmek için negatif çiftleri kullanmamaktadır. Zaman serisi verilerinin temsillerini üretmek için Zamansal Evrişimsel Ađlar (ZEA, Temporal Convolutional Networks-TCN) ve LSTM tabanlı bir kodlayıcı-kod çözücü modelini eğitmektedir.



Şekil 2.5. COCA modelinin mimarisi

Elektrokardiyografi (EKG) verilerindeki anomali durumlarını tespit etmek kalbin durumu hakkında bilgi verici olabilmektedir. Bu nedenle Li vd. (2022) modelin veri dengesizliği ve dayanıklılık problemlerini hafifletebilmek için veri artırma tabanlı karşılaştırmalı öğrenme modeli önermektedirler. Çift Yönlü LSTM (ÇYUKSB, Bidirectional LSTM-BiLSTM) ve Zaman Serisi Üretken Çekişmeli Ağlar (ZSÜÇA, Time-series Generative Adversarial Networks-TimeGAN) olan iki ayrı veri artırma yöntemi sunulan çalışmada yöntemleri önceden eğitilmiş modeller kullanmaktadır. Her veri için bu iki yöntem kullanılarak ayrı ayrı veri artırımı gerçekleştirilip kodlayıcı ve çözümleyiciden geçerek ikisi içinde vektörler elde edilmektedir. Bu ikisi arasındaki benzerlik, güçlü veri temsilini elde etmek için hesaplanmaktadır. Daha sonra karşılaştırmalı öğrenme modülünde, ilk olarak projektör başı kullanılarak bağlam üzerinde doğrusal olmayan bir dönüşüm uygulanmaktadır. Bu kısım kontrastın uygulandığı alanın bağlam bilgilerini hesaplamaktadır. Ardından iki artırılmış temsillerin benzerlikleri maksimize edilmektedir. Orijinal veriler karşılaştırıldıktan sonra sinyallerdeki anomali tespiti için Şekil 2.6'daki süreç uygulanmaktadır. İki ayrı veri seti kullanılarak çalıştırılan anomali tespiti metodunun doğruluk oranı üç farklı metot ile karşılaştırılmış ve %94 üzerinde doğruluk oranı vererek

başarı olmaktadır. Çalışmanın kardiyovasküler hastalıkların önlenmesi için yeni bir bakış açısı sunduğu savunulmaktadır.



Şekil 2.6. EKG anomali tespiti modeli (Li vd., 2022)

### 3. TEMEL KAVRAMLAR

#### 3.1. Anomali Tespiti

Anomali, normal veya beklenen davranışların dışındaki durum veya olaylar olarak tanımlanabilmektedir. Bir trafikteki ani yoğunluk veya bir kişinin dakikadaki ortalama kalp atış hızındaki farklılıklar anomali olarak değerlendirilmektedir. Teknolojinin gelişmesi ile birlikte üretilen veriler her geçen gün artmaktadır. Bu veriler üzerindeki normal olmayan anlık veya belirli süreli değişiklikleri takip etmekte zorlaşmaktadır. Günümüzdeki bu veri artışı, verilerin analizini zorlaştırmakta ve verilerin anlamlandırılabilmesinin daha karmaşık olmasına sebep olmaktadır. Anomali tespiti ise veriler üzerindeki anomali durumlarını tespit edebilmek için ortaya atılan bir tekniktir. İlk zamanlarda hata tespiti amacıyla ortaya çıkan bu teknik, artık yapay zekanın gelişmesi ve veri biliminin de ortaya çıkması ile birlikte daha geniş bir uygulama alanında kullanılmaktadır. Bunlara sağlık, güvenlik, finans gibi örnekler verilebilmektedir.

#### 3.2. Yapay Zeka

Bilgisayar sistemlerinin ve yazılımların insan benzeri zeka davranışları gösterebilmesini sağlayabilmesi için ortaya çıkan bilime yapay zeka denmektedir. Alan Turing 1950'li yıllarda insanların sorunlarını çözmek için mevcut bilgiyi de kullandığını belirterek, makinelerinde aynı şeyi yapıp yapamayacağını sorgulamaktadır. Ancak o yıllarda bilgisayarlar komutları saklayamamaktadır. Bu nedenle bilgisayara yapması gereken iletilebilmekte ancak bilgiyi saklayamadıkları için makinelerin bilgiyi kullanması zor olmaktadır. Ancak günümüzde ise teknolojinin gelişmesi ile birlikte büyük veriler oluşmaktadır. Bu durum bilgilerin makine tarafından kullanılmasına ve öğrenmesine olanak sağlamaktadır. Böylelikle makine öğrenimi ve derin öğrenme gibi yapay zeka teknolojileri ortaya çıkmaktadır. İnsanların zamanını alan görevleri otomatikleştirmesi, büyük veriyi

kolay işleyebilmesi, hataları minimize etmesi gibi avantajları olmasına rağmen güvenilirlik karmaşıklık ve gizlilik gibi dezavantajları da bulunmaktadır.

### 3.3. Makine Öğrenimi

Bilgisayar bilimcisi Alan Turing tarafından 1950'li yıllarda makine öğrenimi alanı kurulup, 1959 yılında da Arthur Samuel tarafından makine öğrenimi terimi ortaya atılmaktadır. Makine öğrenimi yapay zekanın alt dallarından biridir ve çevredeki ortamdan öğrenerek insan zekasını taklit etmek için tasarlanmış, gelişen bir hesaplamalı algoritma dalıdır (Naqa ve Murphy, 2015). Bu nedenle veri odaklı bir teknolojidir ve verilerdeki anlamlı ilişkilere odaklanmaktadır. Bu bilgiler doğrultusunda geçmişteki verileri kullanarak öğrenir ayrıca otomatik olarak da geliştirebilmektedir. Günümüzde sağlık, ekonomi, ulaşım gibi birçok alanda kullanılan makine öğrenimi, veriler üzerinde eğitilerek problemlerin çözülmesini hedefleyen bir teknoloji olarak da tanımlanabilmektedir.

Makine öğrenimi algoritmasının çalışabilmesi için öncelikle veri toplanmalıdır. Bu veriler resim, metin, sinyal, ses gibi çeşitli formatlarda olabilir. Önemli olan hedeflenen çözüm için gerekli örnekleri içermesidir. Ardından toplanan bu veriler ön işleme aşamasından geçmektedir. Bu aşamada eksik olan değerler temizlenebilir, veriler normalleştirilebilir ve eğitim ve test olmak üzere veri seti ayrılabilir. Artık hazır olan verilere ve hedeflenen çözüme uygun makine öğrenimi modeli seçilmelidir. Seçilen model ön işleme aşamasında eğitim olarak ayrılan veriler ile eğitilerek veriler arasındaki ilişkilerin öğrenilmesi sağlanmaktadır. Model eğitildikten sonra performansının değerlendirilebilmesi için ön işleme aşamasında test için ayrılan veri seti kullanılmaktadır. Bu aşamada doğruluk, kesinlik, duyarlılık gibi metrikler hesaplanarak modelin ne kadar iyi çalıştığı değerlendirilmektedir. Çıkan sonuç doğrultusunda performansı daha da artırabilmek için hiperparametreler ayarlanabilmektedir. Son olarak eğitilen model artık yeni veriler üzerinde kullanılarak sınıflandırma yapılabilmektedir.

Makine öğrenimi algoritmalarının performansını değerlendirmek için çeşitli ölçüm metrikleri bulunmaktadır. Bu ölçüm metriklerinin hesaplanabilmesi için kullanılan dört adet temel kategori bulunmaktadır. Bunlar karmaşıklık matrisi olarak adlandırılmakta ve Çizelge 3.1’de gösterilmektedir.

Çizelge 3.1. Karmaşıklık matrisi

		Tahmin Edilen Değer	
		Pozitif	Negatif
Gerçekleşen Değer	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Karmaşıklık matrisinde belirtilen DP alanı verinin gerçekte pozitif olarak sınıflandırıldığı ve tahmin edilen değer de pozitif olarak sonuç vermesi ile birlikte doğru olduğunu göstermektedir. DN alanı ise negatif olarak sınıflandırılan verinin, negatif olarak tahmin edildiğini göstermektedir. Bu durumda da doğru sonuç elde edilmektedir. YP olarak adlandırılan alan gerçekte negatif sınıflandırılan verinin pozitif olarak tahmin edildiği göstermektedir ve yanlış alarm vermektedir. YN olarak adlandırılan alan ise gerçekte pozitif olarak sınıflandırılan verinin negatif olarak tahmin edildiğini göstermektedir. Bu durumda da gözden kaçırma durumu ortaya çıkmaktadır.

Karmaşıklık matrisi içerisindeki bilgiler kullanılarak hesaplanan ölçüm matrisleri aşağıdaki gibidir.

- **Doğruluk (Accuracy):** Tüm veri setinde yapılan doğru tahminleri ölçmektedir. Denklem 3.1'deki gibi doğru tahmin edilen verilerin toplam örnek sayısına bölünerek hesaplanan değerdir ve doğru sınıflandırma oranını göstermektedir.

$$Doğruluk = \frac{(DP+DN)}{(DP+DN+YP+YN)} \quad (3.1)$$

- **Kesinlik (Precision):** Denklem 3.2'deki gibi veri setinde pozitif olarak sınıflandırılan ve pozitif olarak tahmin edilen değerlerin, pozitif tahmin edilen değerlere oranı alınarak ölçülmektedir. Pozitif tahminlerin ne kadar olduğunu göstermektedir.

$$Kesinlik = \frac{DP}{(DP+YP)} \quad (3.2)$$

- **Duyarlılık (Recall):** Gerçek pozitiflerin ne kadarının doğru tahmin edilebildiğini göstermektedir ve Denklem 3.3'teki gibi pozitif sınıflandırılıp pozitif tahmin edilen değerlerin gerçekte pozitif olan değerlere oranı ile bulunmaktadır.

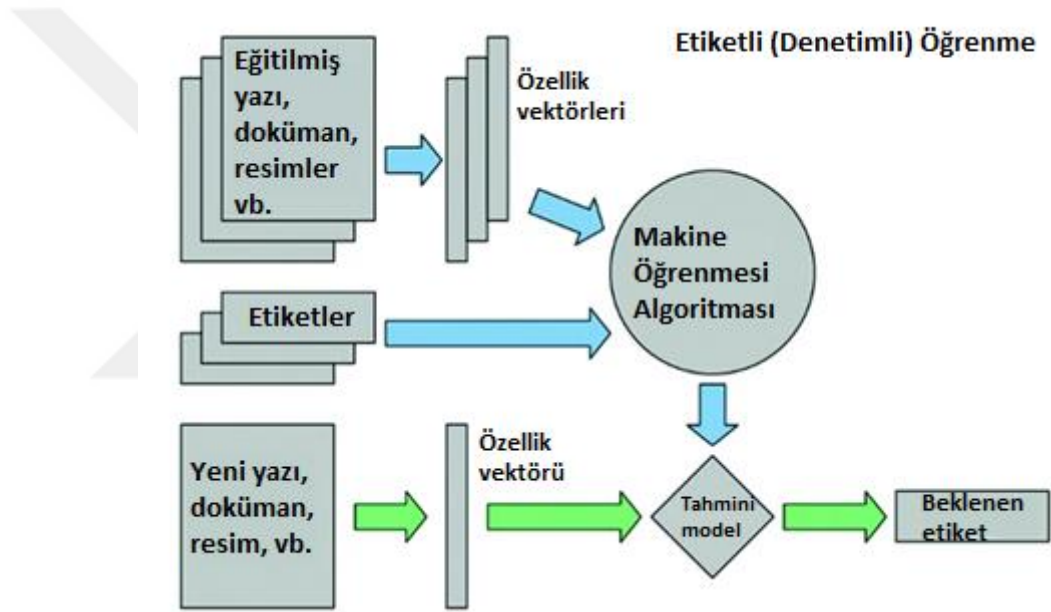
$$Duyarlılık = \frac{DP}{(DP+YN)} \quad (3.3)$$

- **F1 Skoru (F1 Score):** Denklem 3.4'teki gibi kesinlik ve duyarlılığın harmonik ortalaması ile elde edilen bu ölçüm değeri, iki değer arasında denge kurması açısından önemlidir.

$$F1 Skoru = 2 * \frac{(Kesinlik * Duyarlilik)}{(Kesinlik + Duyarlilik)} \quad (3.4)$$

### 3.3.1. Etiketli (Denetimli) öğrenme (supervised learning)

Denetimli öğrenme veri seti içerisinde bulunan etiketlerden çıkarım yaparak sonuca ulaşan öğrenme yöntemidir. Denetimli öğrenmenin amacı, Şekil 3.1’de de gösterildiği gibi geçmişteki veri setinin içerisindeki etiket verisini de dikkate alarak yeni gelen veriler üzerinden girdi ve çıktı arasındaki ilişkiyi en iyi şekilde tahmin eden bir model oluşturmaktır. Etiket işlemleri üzerinden işlem yapıldığı için etiketsiz öğrenmeye göre daha hızlı bir şekilde sonuç vermektedir.



Şekil 3.1. Denetimli öğrenme modeli (Desarkar ve Das, 2017)

### 3.3.2. Etiketsiz (Denetimsiz) öğrenme (unsupervised learning)

Denetimsiz öğrenme, içerisinde herhangi bir bilgi sonucu olmayan veri seti üzerinden çıkarım yapılan öğrenme yöntemidir. Çıkarım daha çok etiketsiz verilerde birbirine en yakın sonuçları kategorize ederek yapılmaktadır.

### 3.3.3. Yarı denetimli öğrenme (semi-supervised learning)

Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenme yöntemlerinin orta noktasını bulmaktadır. Etiketli ve etiketsiz veriler bir arada kullanılarak daha etkili bir öğrenme yöntemi sunmaktadır. Bu sayede makine öğrenimi modellerindeki etiketlenme maliyetlerini düşürmektedir ve performansı arttırmaktadır.

### 3.3.4. Pekiştirmeli öğrenme (reinforcement learning)

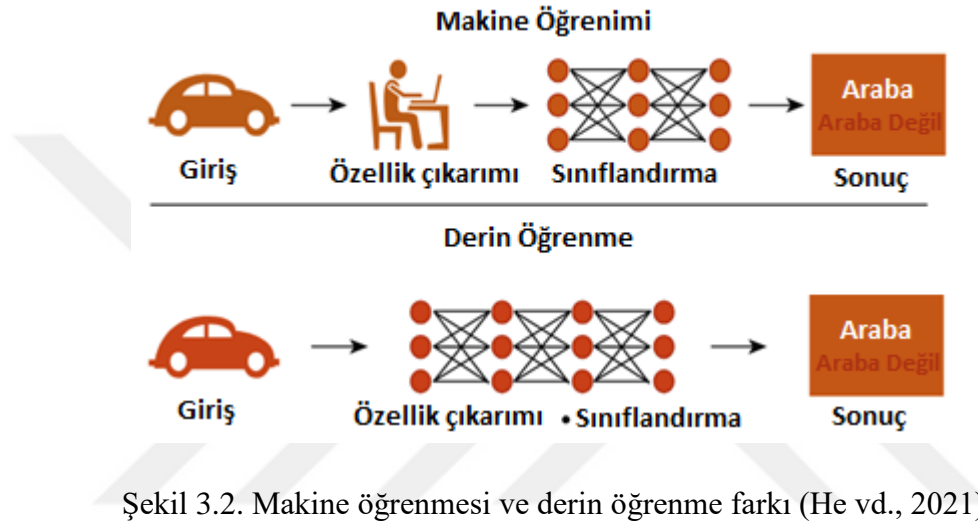
Geçmiş deneyimlerden ders alıp, en iyi sonu elde etmek amacıyla ortaya çıkan pekiştirmeli öğrenme, makineye deneme yanımıyla işlemini öğretmektedir. Makine öğrenmesi algoritmasının sağlamış olduğu eylem, parametre ve son değerlere odaklanmaktadır. Genellikle robotik, oyun ve navigasyon için kullanılmaktadır ve amacı en iyi politikayı öğrenmektir (Ongsulee, 2017).

## 3.4. Derin Öğrenme

Hao vd. (2016) derin öğrenmeyi, karmaşık yapılardan veya doğrusal olmayan dönüşümlerden oluşan çok sayıda nöron katmanının kullanarak yüksek düzeyde veri soyutlamalarını modellemeye çalışan bir makine öğrenimi dalı olarak tanımlamaktadır. Bilgisayarlı görü, doğal dil işleme, konuşma tanıma, sağlık, finans gibi birçok alanda kullanılan derin öğrenme özellikle fazla veri artışı ile hesaplama işlemlerinin de zorlaşması nedeniyle ortaya çıkmaktadır. Derin öğrenme makine öğrenmesinin alt kümesidir ve farkları aşağıdaki gibidir.

- Veri setindeki ilişkileri öğrenebilmek için makine öğrenmesindeki istatistiksel algoritmaların aksine yapay sinir ağı mimarisini kullanmaktadır.
- Makine öğrenmesiyle karşılaştırıldığında daha büyük veri setleri ile çalışabilmektedir.
- Modeli eğitmek daha fazla zaman almaktadır.

- Şekil 3.2’de gösterildiği gibi makine öğrenmesinde görüntülerden manuel çıkarılan özellikler ile model oluşturulur ancak derin öğrenmede özellikler otomatik olarak çıkarılarak uçtan uca bir öğrenme süreci gerçekleşmektedir.
- Yüksek performanslı bilgisayarlara gerek duymaktadır.
- Makine öğrenmesine kıyasla daha karmaşıktır.

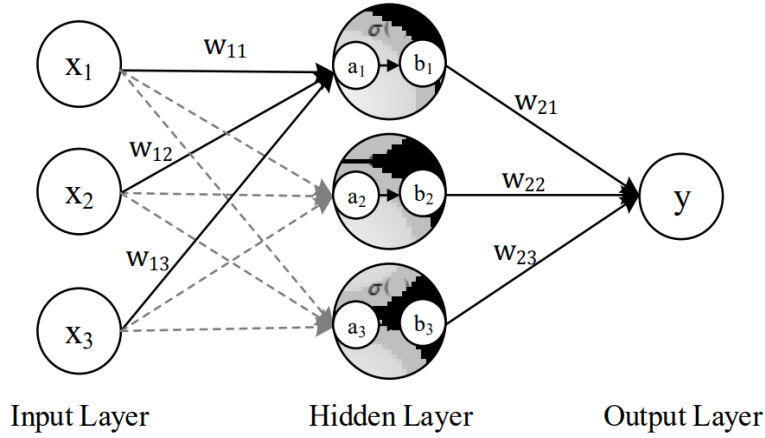


Şekil 3.2. Makine öğrenmesi ve derin öğrenme farkı (He vd., 2021)

### 3.5. Sinir Ağları (Neural Networks)

Biyolojik sinir ağları birbirlerine nöronlar ile bağlanmaktadır. İnsan beynindeki bu sinir ağlarından esinlenerek makineler içinde aynı yapı kurulabilmesi amacıyla ortaya çıkan yapay sinir ağları, birbirine bağlı elemanlardan oluşmakta ve öğrenme, modelleme, tahmin etmek gibi görevlerde kullanılmak üzere çıkan derin öğrenme modelleridir.

Bir sinir ağının işlevi, bir giriş modeli ile sunulduğunda bir çıktı modeli üretmektir (Picton, 1994). Şekil 3.3’te de görüldüğü gibi yapay sinir ağları bileşenleri girdi katmanı, gizli katmanlar, çıktı katmanı, nöronlar, ağırlıklar ve önyargılardan (biases) oluşmaktadır.




Şekil 3.3. Yapay sinir ağı bileşenleri (Torky ve Aburawwash, 2018)

- **Girdi katmanı:** Modele verinin giriş yaptığı katmandır.
- **Gizli katmanlar:** Öğrenme sürecini gerçekleştirip, veriler üzerinde hesaplamalar yaparak özellikler çıkaran katmandır.
- **Çıktı katmanı:** Modelin sonuç verdiği, tahmin veya sınıflandırmanın yapıldığı katmandır.
- **Nöronlar:** Her katmanda bulunan nöronlar, hesaplama birimleri olarak tanımlanabilir. Bir önceki katmandan gelen bilgileri alıp ağırlık ve önyargı değerleri ile işleyerek çıktıyı bir sonraki katmana aktarırlar.
- **Ağırlık ve önyargılar:** Bir sinir ağında bulunan nöronlar arasındaki bağlantıların hepsi eşit değildir. Nöronlar arasındaki bağlantının katsayısına ağırlık denmektedir. Bu şekilde bağlantılar arasındaki kuvveti belirlemektedir. Önyargılar ise her nöronla ilişkili sabitler olarak tanımlanmaktadır.

### 3.6. Evrimsel Sinir Ağları (Convolutional Neural Networks-CNN)

Bir tür sinir ağı modeli olan evrimsel sinir ağları, evrim katmanları, havuzlama katmanları ve tam bağlantılı katmanlar gibi birden fazla yapı bloğu kullanarak geri yayılım yoluyla özelliklerin uzamsal hiyerarşilerini otomatik ve uyarlanabilir bir şekilde öğrenmek

için tasarlanmıştır (Yamashita vd., 2018). Genellikle görüntü ve video verileri üzerinde kullanılmaktadır ve basit bir düzeyde mimarisi Şekil 3.4'teki gibidir.



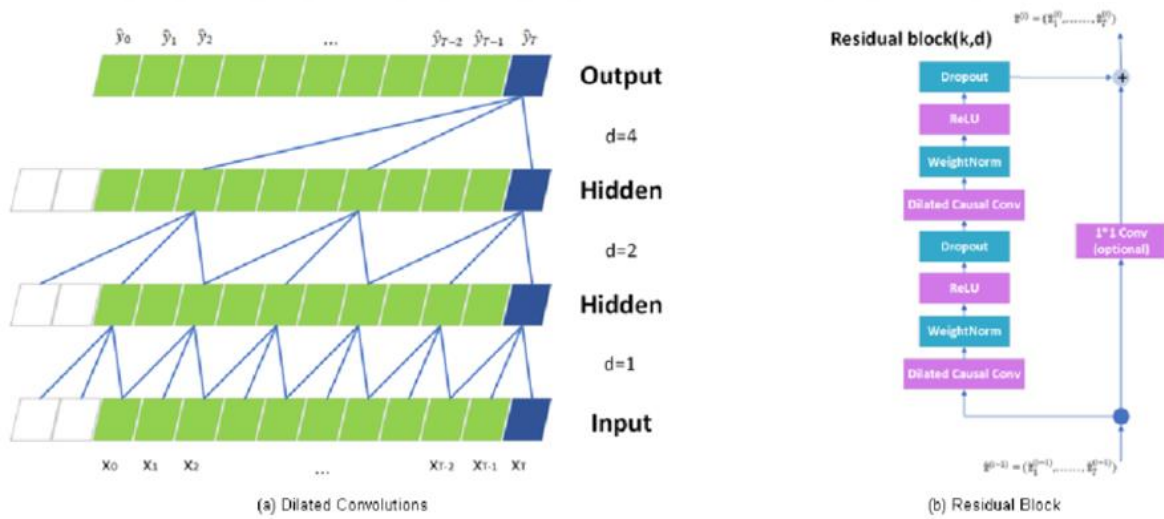
Şekil 3.4. CNN mimarisi (Gu vd., 2019)

Basit bir CNN mimarisinde bulunan katmanlar ve görevleri aşağıdaki gibidir.

- **Giriş katmanı:** Modele giriş yapacak olan verinin bulunduğu katmandır. Bu veriler metin, görüntü gibi örnekler olabilmektedir.
- **Evrişimli katman:** Giriş yapan verinin çeşitli filtreler ile işlenmesini sağlayan katmandır. Böylelikle giriş verisindeki özellikler çıkarılmaktadır.
- **Havuzlama katmanı:** Evrişimli katmandan özellikleri çıkarılan veriler bu katmanda küçültülerek önemli bilgilere ulaşılmaktadır. Aşırı öğrenme riskini ve modelin hesaplama yükünü azaltan bu katmanın maksimum havuzlama ve ortalama havuzlama olmak üzere iki çeşidi vardır.
- **Tam bağlantılı katman:** Evrişimsel ve havuzlama katmanından gelen tüm bilgileri tek bir vektöre dönüştüren bu katman aslında bir yapay sinir ağı katmanıdır. Her nöronun tüm girdilerle bağlantısı bulunmaktadır. Ağırlık, önyargılar, aktivasyon fonksiyonları bu katmanda kullanılmaktadır.
- **Çıkış katmanı:** İstenilen tahminlerin elde edildiği, modelin son çıktısını üreten katmandır.

### 3.7. Zamansal Evrişimsel Ağlar (Temporal Convolutional Networks-TCN)

Genellikle zaman boyutundaki veriyi işlemek amacıyla tasarlanan zamansal evrişimsel ağlar, evrişimsel sinir ağlarından farklı olarak zaman bağımlılıklarını yakalamak için kullanılmaktadır. İlk olarak Lea vd. (2016) ortaya çıkardığı derin öğrenme mimarilerinden biri olan TCN özellikle zaman serisi verilerinde daha etkili ve hızlıdır. Zaman serisi verilerini işleyebilmek için evrişimsel katmanlar kullanılmaktadır. Bu yaklaşımda iki adet aşama bulunmaktadır. Birincisi CNN kullanarak düşük seviyeli özelliklerin çıkarımı, ikincisi ise çıkan bu özelliklerin bir yüksek seviyeli zamansal bilgiyi sınıflandırıcıya giriş yapmasıdır. Şekil 3.5'te gösterilen TCN mimarisine bakıldığında görüldüğü gibi CNN'lerden farklı olarak genişlemiş evrişimsel katmanlardan oluşmaktadır. Bu katmanlar zaman serisindeki farklı özellikleri yakalamak için artan bir pencere boyutu ile ilerlemektedir. Bu sayede her çıktı, giriş dizisindeki tüm verilerin etkisini almaktadır. Daha az gizli katman kullanmakta ve optimizasyon algoritması olan geriye yayılım ile eğitilmektedirler.



Şekil 3.5. TCN mimarisi (Song vd., 2023)

### 3.8. Veri Artırma (Data Augmentation)

Veri artırma, makine öğrenmesi alanında çokça kullanılan bir tekniktir. Bu teknik, mevcut verinin seti üzerinde çeşitli dönüşümler uygulanarak arttırılmasını amaçlamaktadır. Özellikle sınırlı bir veri seti ile çalışılırken veri artırımını uygulanacak olan modelin daha başarılı olmasına olanak sağlamaktadır. Örneğin Şekil 3.6'daki gibi görüntüler üzerinde, görüntünün döndürülmesi, kırılması, renginin değiştirilmesi, boyutunun değiştirilmesi gibi birçok veri artırma tekniği bulunmaktadır. Veri artırımının doğru kullanılması ile birlikte makine öğrenmesi yöntemlerinde daha başarılı sonuçlar elde edilebileceği görülmektedir.




Şekil 3.6. Veri artırımını örneği (Le-Khac vd., 2020)

### 3.9. Kayan Pencere Tekniği (Sliding Window)

Diziler veya listeler için geçerli olan kayan pencere tekniği, karmaşıklığı azalmak amacıyla kullanılmaktadır ve bir aralık tanımlayarak o aralık içinde bazı işlemler gerçekleştirmek için aralığı veriler üzerinde hareket ettirerek sorunları çözmektedir. Bu teknik ile daha büyük veri kümesinin birden çok zaman dilimine etkili bir şekilde

bakılabilmekte ve her aralıktaki alt problemler çözülrken pencere tüm veri kümesinde hareket ettirilmektedir (Ratnavale vd., 2022).

Sabit verilen bir  $X$  değeri ile pencere boyutu belirlenmektedir ve ilk pencere belirlenen bu  $X$  boyutunda olmaktadır. Bu pencere içerisindeki veriler ile istenilen hesaplamalar yapılmaktadır. Ardından pencere bir adım kaydırılarak sırasıyla her pencere için hesaplamalar yapılmaktadır.  $X$  pencere boyutu 3 olarak verildiğinde Şekil 3.7'deki gibi yöntem gerçekleştirilmektedir.



Şekil 3.7. Sabit boyutlu kayan pencere tekniği örneği

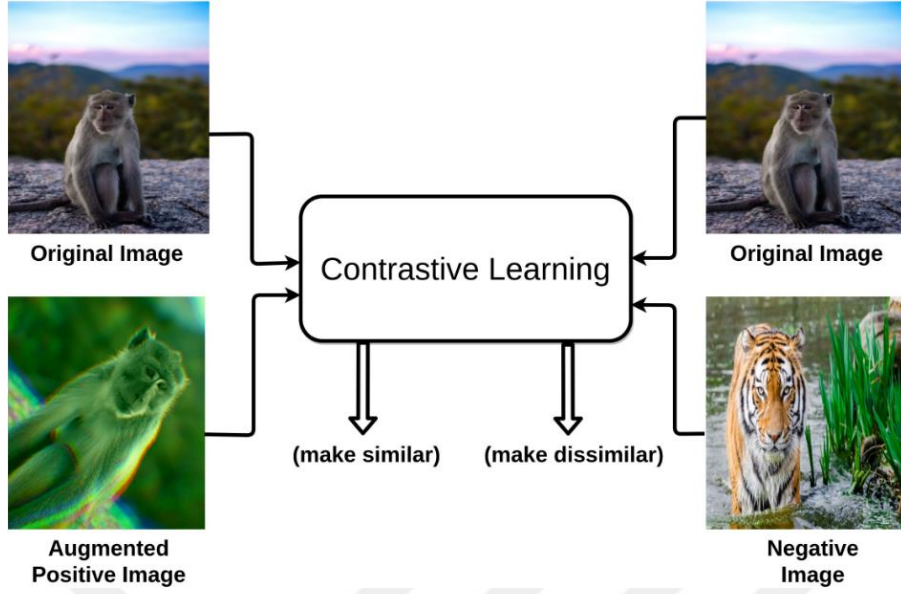
## 4. MATERYAL VE YÖNTEM

Çalışma kapsamında fizyolojik sinyaller kullanarak anomali tespiti yapılması amaçlanmaktadır. Literatürde yapılan birçok çalışmada zaman serisi verileri ile anomali tespiti yapabilmek amacıyla çeşitli yöntemler kullanılmaktadır. Kullanılan yöntemlere her geçen gün bir yenisi eklenmektedir. Son yıllarda karşılaştırmalı öğrenme modeli kullanılarak birçok yöntem önerilmektedir. Karşılaştırmalı öğrenmenin yaygınlaşmaya başlamasıyla beraber, yeni ve başarılı olan bir çalışma kullanılarak kişiselleştirilmiş anomali tespiti yapılabilmesi hedeflenmektedir. Ayrıca ilk olarak belirli bir süre zaman serisi verileri eğitip, ardından zaman serisi verileri anlık olarak test edilerek anomali durumu hakkında bilgi verilmesi amaçlanmaktadır.

### 4.1. Karşılaştırmalı Öğrenme (Contrastive Learning)

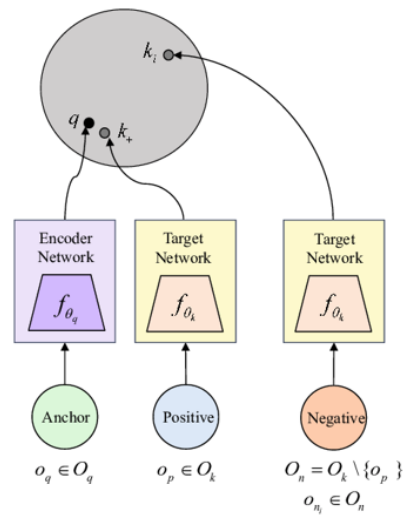
Birbirine benzer ancak farklı olan nesnelere, cümleler veya genel bakılacak olunursa tüm verileri birbirinden ayırt edebilecek birçok makine öğrenimi teknikleri mevcuttur. Bu teknikleri kullanan makineler, örneğin bir kedi ile köpek arasındaki benzerlik ve farklılıkları öğrenerek ayırt etme işlemini gerçekleştirmektedir. Son yıllarda hızla popülerleşen karşılaştırmalı öğrenme tekniği de buna örnek olarak verilebilmektedir. Temelleri 1990'lı yıllara kadar uzanan karşılaştırmalı öğrenme bilgisayarlı görme, doğal dil işleme, ses işleme gibi birçok alanda uygulanmaktadır (Le-Khac vd., 2020).

Karşılaştırmalı öğrenme yöntemi özellikle etiketlenmemiş veriler için uygulanmak üzere ortaya çıkmıştır. Genel olarak amacı, Şekil 4.1.'de gösterildiği gibi benzer örnekleri birbirine yakın konumlandırıp, benzer olmayan örnekleri ise olabildiğince uzak tutmaktır. Böylelikle verilerden alınan örnekler benzerlik ve farklılıklarına göre sınıflandırılıp, birbirleri ile karşılaştırılabilir olmaktadır. Sınırlı etiketli veri ortamlarında da bu sayede performansı arttırmaktadır.



Şekil 4.1. Karşılaştırmalı öğrenme yönteminin arkasındaki yapı (Jaiswal vd., 2021)

Karşılaştırmalı öğrenmenin genel yapısında orijinal veriler, pozitif ve negatif veriler bulunmaktadır. Orijinal veriler üzerinde temsili öğrenmeyi gerçekleştirebilmek için verinin özelliklerini kullanmaktadır. Pozitif örnek ile bağlantılı olduğu verinin örneğini birbirine yakınlştırıp, diğer yandan negatif örneği de uzaklaştırmaktadır. Şekil 4.2’de karşılaştırmalı öğrenmenin temel mimarisi görülmektedir.



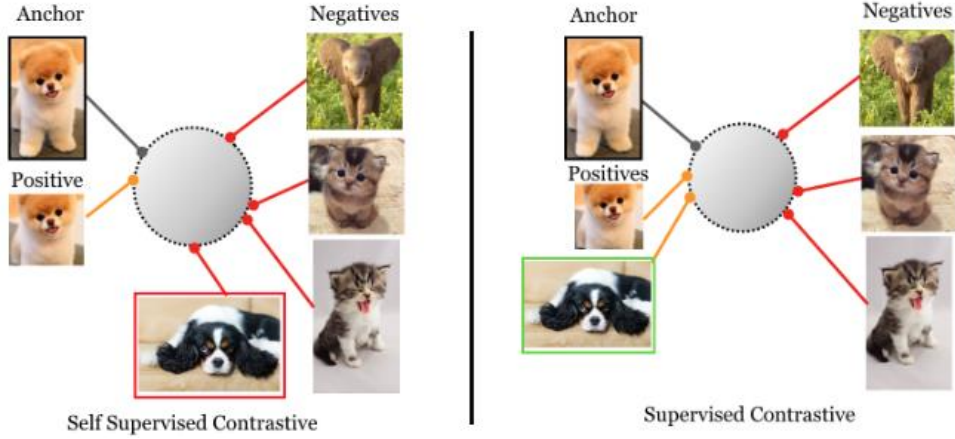
Şekil 4.2. Karşılaştırmalı öğrenme mimarisi (Liu vd., 2022)

#### **4.1.1. Denetimli karşılaştırmalı öğrenme (SCL)**

Karşılaştırmalı öğrenme yöntemine, örnekler üzerindeki benzerlik ve farklılıkları daha iyi ayırt edebilmesi için etiket bilgileri verilerek de eğitim süreci gerçekleştirilebilmektedir. Bu durumda etiketli verileri kullanan karşılaştırma öğrenme SCL (Khosla vd., 2020) olarak adlandırılmaktadır. Verilerin etiketli olması ile birlikte model hem veriler hem de etiketler ile eğitilmektedir. Aynı sınıftaki verileri gruplayıp bunları pozitif olarak, diğer sınıflardaki verileri de negatif olarak değerlendirilmektedir. Böylelikle daha iyi bir sonuç vermesini sağlamaktadır. Ancak sınırlı etiketlenmiş veri miktarı olması ve veri etiketleme maliyeti gibi kısıtları bulunmaktadır.

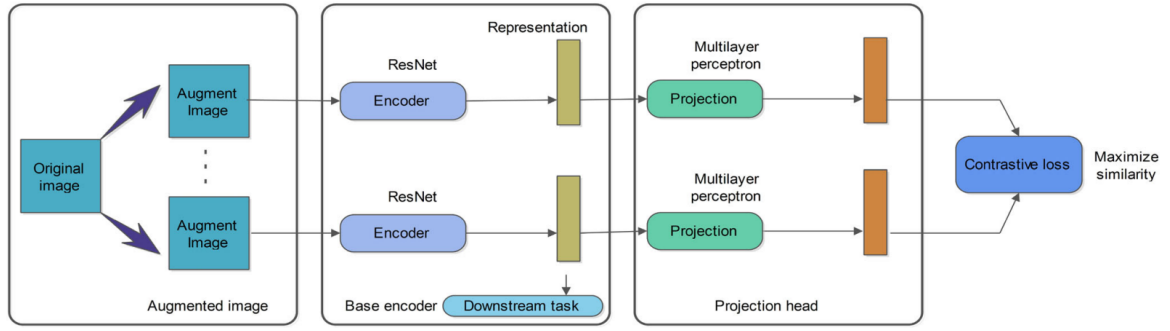
#### **4.1.2. Kendi kendine denetimli karşılaştırmalı öğrenme (SSCL)**

Kendi kendine denetimli karşılaştırma öğrenme yöntemi, etiketsiz veriler üzerinden öğrenme sürecini gerçekleştirerek çalışmaktadır. Benzer verileri birbirine yakın konumlandırıp, farklı verileri ise daha uzak konumlandırmaktadır. Kendi kendine karşılaştırmalı öğrenme yönteminde genellikle orijinal veri arttırılarak yeni bir örnek grubu oluşturulmaktadır. Bu yöntemde her bir veri için aynı verinin sadece bir tane dönüştürülmüş hali kullanılmaktadır. Bu bilgiler pozitif olarak kabul edilip, geriye kalan diğer örnekler negatif olarak kabul edilmektedir. Böylelikle etiket bilgisi olmadan aynı verinin farklı hallerini birbirine yakın konumlandırarak öğrenmektedir. Şekil 4.3'te denetimli ve kendi kendine denetimli karşılaştırmalı öğrenmenin farkını gösteren örnek bulunmaktadır.



Şekil 4.3. Denetimli ve kendi kendine denetimli karşılaştırmalı öğrenme (Khosla vd., 2020)

Kendi kendine denetimli karşılaştırmalı öğrenme çerçevelerine örnek olarak SimCLR (Chen vd., 2020) verilebilmektedir. Bu çerçeve, ilk olarak her veri için veri artırımı yapmaktadır. Artırılmış her veri, temsillerinin elde edilebilmesi için bir kodlayıcıdan geçirilmektedir. Bu kodlayıcılar farklı mimarilerde de olabilir ancak çalışmada evrimsel sinir ağı olan ResNet-50 kullanılmaktadır. Bir sonraki aşama, projeksiyon başlığı diye adlandırılan ve artırılan iki veri temsillerinin doğrusal olmayan Dense, ardından ReLU ve tekrar Dense katmanlarından geçirilmesi işlemleri uygulanarak iki ayrı veri çıkartmaktadır. Dense katmanı bir sinir ağındaki nöronların geçişlerini sağlamaktadır. ReLU ise aktivasyon fonksiyonudur. Bu fonksiyon giriş negatifse 0, pozitif ise giriş değerini döndürmektedir. Ardından aynı veriler için oluşturulan yeni verileri birbirine daha yakın konumlandırmaktadır. Ayrıca bu verileri, diğer verilerden de daha uzak tutmaktadır. Bu işlem için bir önceki aşamada oluşturulan vektörler arasındaki benzerlik kosinüs benzerliği kullanılarak hesaplanmaktadır. Hesaplama sonucunda bir veriye ait olan artırılmış temsillerin benzerlikleri yüksek çıkacaktır. NT-Xent adı verilen karşılaştırma kaybı kullanan bu model, bu aşamada artırılmış çiftler birer birer olarak iki verinin benzer olduğunu olasılığını hesaplayabilmek için softmax fonksiyonunu kullanmaktadır. Bu fonksiyon tek bir çıktı üretmekte ve çıkan sonuç olasılıksal olarak ifade edilmektedir. Sonucunda ise verilerdeki anlamlı benzerlikleri ve farklılıkları yakalayıp bu şekilde öğrenme gerçekleştirmektedir. Genel olarak veri setinde etikete ihtiyaç duymadan, verileri kullanarak kendi kendine öğrenmeyi amaçlamaktadır. SimCLR mimarisi Şekil 4.4'teki gibidir.



Şekil 4.4. SimCLR mimarisi (Kumar vd., 2022)

## 4.2. Veri Seti

Çalışma kapsamında fizyolojik sinyalleri kullanarak stres tespiti ve oyun tepkisini ölçmek amacıyla ortaya çıkan AKTIVES (Coşkun vd., 2023) veri seti kullanılmaktadır. Veri seti obstetrik brakial pleksus yaralanması, disleksi, zihinsel engelli ve tipik olarak gelişmiş 25 çocuktan elde edilen BVP, EDA, ST verilerini içermektedir. Bu verileri toplarken Şekil 4.5'teki gibi bileklik kullanılmaktadır. İki ayrı oyun oynayan çocuklardan ayrıca video görüntüleri de kaydedilmekte ve veri seti görüntüleri de içermektedir. Belirli rahatsızlıklara sahip olan bu çocuklarda stres tespitinin yapılabilmesi gelişimleri açısından önem taşımaktadır. Bu nedenle ortaya çıkan veri seti 3 uzman tarafından stresli/stresli değil ve tepki var/tepki yok şeklinde etiketlenmektedir. Bu etiketlemeler çocukların videolarındaki yüz ifadelerinin incelenmesi sonucunda ortaya çıkmaktadır.



Şekil 4.5. AKTIVES veri toplama süreci (Coşkun vd., 2023)

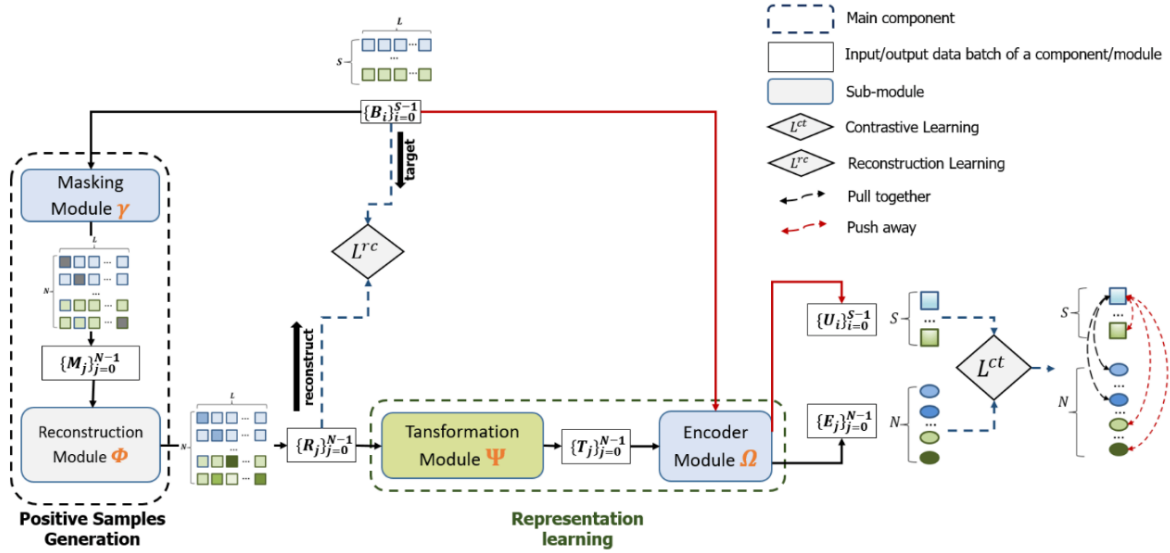
Kullanılan veri setindeki etiketlemeler her 10 saniyelik aralık için yapılmaktadır. Bu kapsamda zaman serisi içeren veriler 3 uzman tarafından değerlendirildiği için en az 2 uzmanın stresli olarak belirtmiş olduğu aralıklar çalışma kapsamında anomali olarak değerlendirilmektedir. Verilerin bu şekilde düzeltilmesi için yeni bir kolon daha oluşturularak etiket bilgisi eklenmektedir. Dosyalardaki 10 saniyeye karşılık gelen bilgi için etiket kolonuna stresli ise 1, stresli değil ise 0 yazılmaktadır. Veri setindeki her çocuk özelinde toplamda 3 adet (BVP, EDA, ST) veri seti bulunmaktadır. Toplanan BVP verileri için frekans 64 Hz, EDA ve ST verileri için ise 4 Hz'dir. Ayrıca veriler oyun oynanırken toplandığı için her çocuğun oyun süresi de farklılaşmaktadır. Bu nedenle verilerin boyutları birbirinden farklı olmaktadır. Etiket verilerinin eklenmesi ile bu veri setleri güncellenmiştir. Sonuç olarak toplam 75 dosyadan oluşan veri seti çalışmada kullanılmaktadır. Ayrıca veri setinde kullanılan fizyolojik sinyaller aşağıda açıklanmaktadır.

- **Kan Hacmi Nabzı (BVP):** Kan hacminde meydana gelen değişiklikleri ölçen biyometrik sinyaldir. Kan hacmi genliğine dönüştürülen periferik banız dalga formunu tespit etmek için yaygın olarak kullanılmaktadır (Lin vd., 2015).
- **Elektrodermal Aktivite (EDA):** Ter üretimindeki ve ter kanallarındaki sıvı konsantrasyonundaki değişikliklerden kaynaklanan, cildin elektrik iletme yeteneğindeki değişikliklerin bir ölçüsüdür (Kushki vd., 2011).

- **Deri Sıcaklığı (ST):** Vücudun en dış yüzeyindeki ısıyı ifade etmektedir. Vücut ısısındaki artış veya azalma deri sıcaklığını da etkilemektedir.

### 4.3. Zaman Serisi Anomali Tespiti için Karşılaştırmalı Öğrenme Yöntemi (CL-TAD)

Ngu vd. (2023) tarafından yapılan çalışma kapsamında zaman serisi verilerinde anomali tespiti için karşılaştırmalı öğrenme kullanılarak yeni bir yöntem önerilmiştir. Bu yöntemin yenilikçi yaklaşımı, rastgele maskelenmiş örnekler kullanarak eğitim verilerini bir kodlayıcı-kod çözücü tabanlı yeniden yapılandırma modülü ile artırıp, bu örnekler ile orijinal örnekleri kullanarak karşılaştırmalı öğrenme gerçekleştirmesidir. Orijinal verilerin temsilleri ile bunlara karşılık gelen yeniden yapılandırılmış verilerin temsilleri arasındaki farkları hesaplayarak anomali tespiti yapılmaktadır. Genel olarak yöntem temsil öğrenme ve anomali tespiti olmak üzere iki aşamadan oluşmaktadır ve modelin ana yapısı Şekil 4.6'da gösterilmektedir.




Şekil 4.6. CL-TAD modeli (Ngu vd., 2023)

Önerilen yöntem bir boyutlu veya iki boyutlu veriler içeren 9 farklı veri setinde denenmiş, ayrıca 10 farklı anomali tespiti metodu ile sonuçları karşılaştırılmış. Diğer anomali tespiti metotları ile karşılaştırıldığında 5 veri setinde diğerlerine göre en iyi

performansı elde etmiştir. Yüksek başarı oranı nedeniyle de çalışma kapsamında CL-TAD yöntemi kullanılmaktadır.

Önerdikleri yöntem de öncelikle problem tanımlanmaktadır. Zaman serisi verilerde anomali tespiti yapılmak istendiğinde sonucunda zamana karşılık değerleri içeren bir dizi çıkması beklenmektedir. Bu doğrultuda çalışma kapsamında diğer derin öğrenme yöntemlerindeki gibi kayan pencere kullanarak Şekil 4.7'deki gibi uzunluğu  $L$  olan  $X$  dizisinden alt dizi örnekleri oluşturularak eğitim veri seti oluşturulmaktadır.



Şekil 4.7.  $X$  zaman serisi dizisinden,  $W$  alt dizi örneklerinin oluşturulması (Ngu vd., 2023)

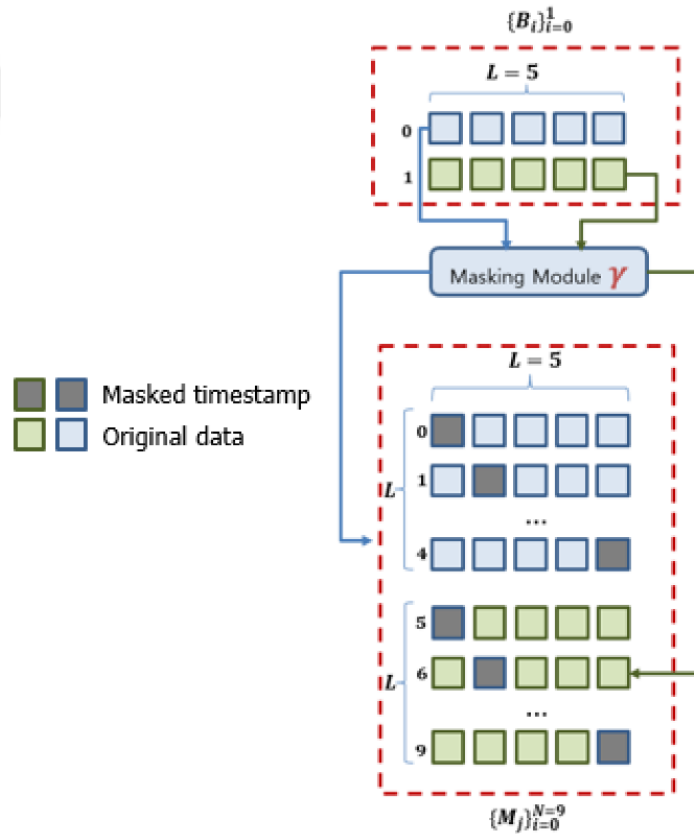
#### 4.3.1. Temsil öğrenme aşaması

Karşılaştırmalı öğrenme tabanlı bir temsil öğrenme modülü tarafından zaman serisinin sabit uzunluktaki alt dizileri ve bunların artırılmış alt dizileri için gizli temsiller üretilmektedir. Temsili öğrenme mimarisi yeniden yapılandırma tabanlı pozitif öğrenme oluşturma ve karşılaştırmalı öğrenme tabanlı temsili öğrenme olmak üzere iki anda bileşenden oluşmaktadır.

#### 4.3.1.1. Pozitif örnek oluşturulması

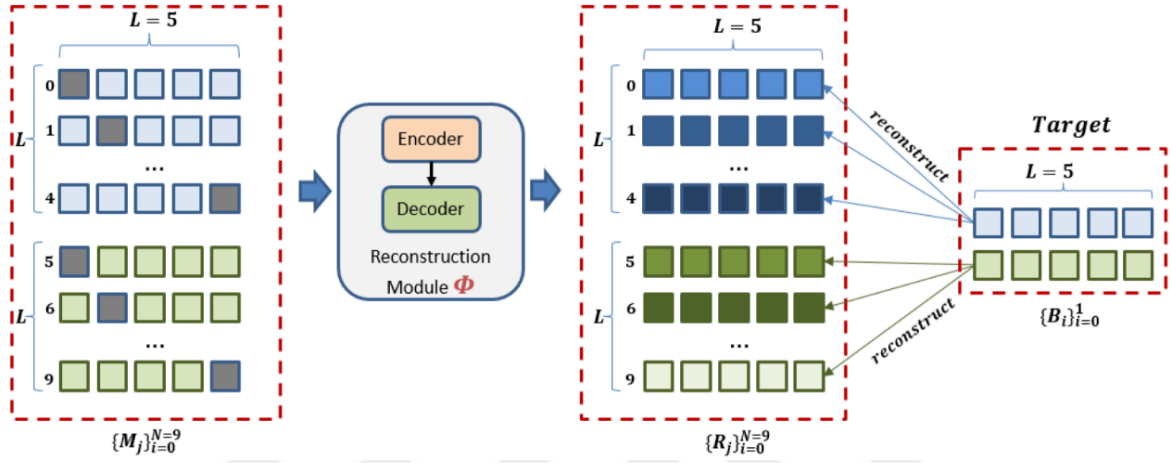
Her bir giriş alt dizi örneğine karşılık pozitif örnekler oluşturmak için tasarlanan pozitif örneklerin oluşturulması aşaması, maskeleme ve yeniden yapılandırma tabanlı kodlayıcı-kod çözücü modüllerini içermektedir.

Orijinal veriden öncelikle orijinal alt dizi örnekleri oluşturulmaktadır. Ardından bu örneklerin her öğrenme sürecinde, önce orijinal veriden belirli bir uzunlukta olan alt dizi örneklerinden oluşan yığın seçilmektedir. Maskeleme modülü bu yığından N maskeleme örneklerinden oluşan yeni bir yığın üretmektedir. Şekil 4.8’de her biri 5 uzunluğundaki alt dizi örneğinden, 10’luk maskelenmiş bir yığın oluşturma sürecini göstermektedir.



Şekil 4.8. Her biri 5 uzunluğundaki alt dizi örneğinden, 10’luk maskelenmiş bir yığın oluşturma süreci (Ngu vd., 2023)

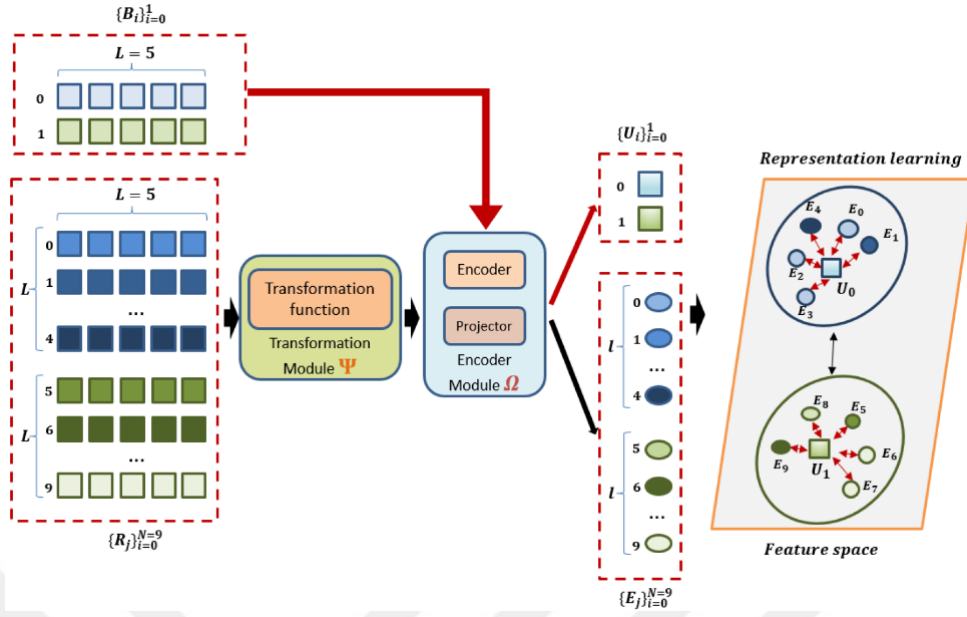
Yeniden yapılandırma tabanlı kodlayıcı-kod çözücü modülünde, oluşturulan maskeleme örneklerine ait yığın orijinal örneğinin yeniden yapılandırılabilmesi sağlanmaktadır. Bu modülde kodlayıcı için zamansal evrişimsel ağ (temporal convolutional network-TCN) ağı ve çözücü için doğrusal katman (linear layer) kullanılmaktadır. Bu modüle ait yapı Şekil 4.9’da gösterilmektedir.



Şekil 4.9. Yeniden yapılandırma tabanlı kodlayıcı-kod çözücü modülü

#### 4.3.1.2. Karşılaştırmalı öğrenme tabanlı temsil öğrenmesi

Öğrenilebilir dönüşüm modeli ve bunu izleyen kodlayıcı modülü içeren karşılaştırmalı öğrenme modülü, anomali değerlendirmeleri için temsilleri üretmek amacıyla önerilen metotta kullanılmaktadır. Bu aşamada hem orijinal veriler hem de yeniden yapılandırılmış örnekler eğitim verisi olarak karşılaştırmalı öğrenme modülünde kullanılmaktadır. Orijinal örnekler doğrudan kodlayıcı modülünde işlenirken, yeniden yapılandırılmış örnekler önce dönüşüm modülünden geçmektedir. Karşılaştırmalı öğrenme tabanlı temsil öğrenme aşamasının yapısı Şekil 4.10’daki gibidir.



Şekil 4.10. Karşılaştırmalı öğrenme tabanlı temsil öğrenmesi mimarisi (Ngu vd., 2023)

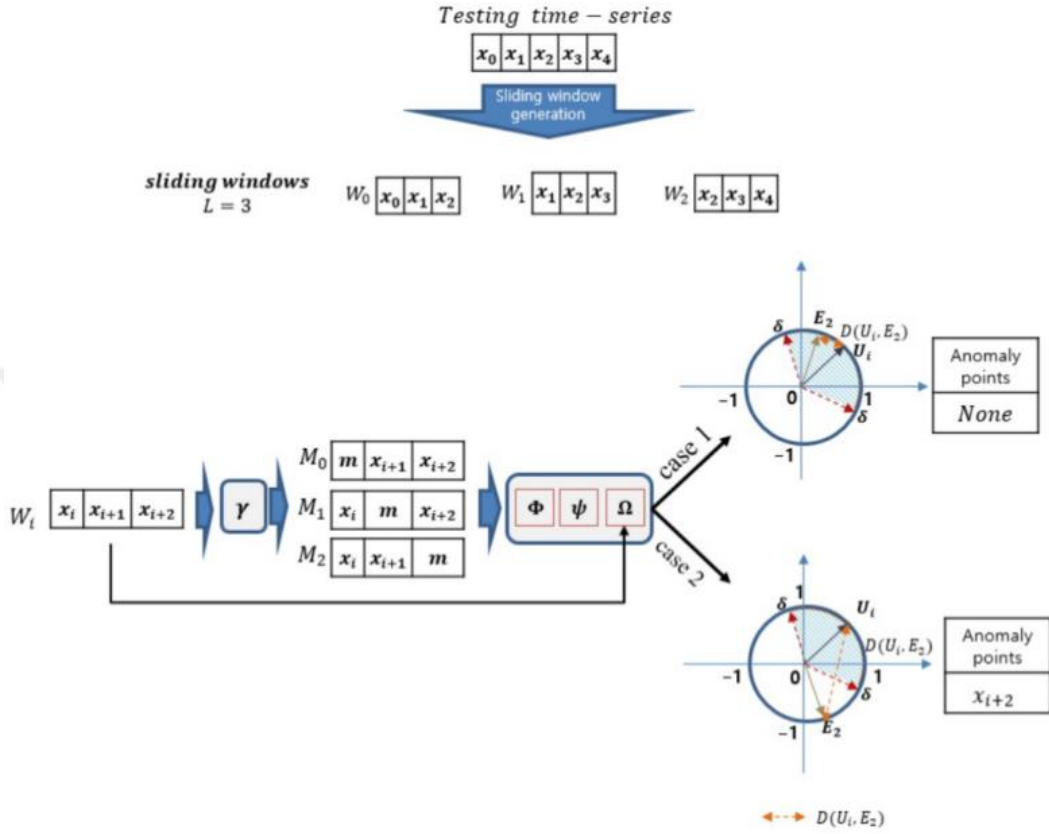
#### 4.3.2. Anomali tespiti aşaması

Her alt dizi için son adım maskelenmektedir ve bu şekilde maskelenmiş alt dizi oluşturulmaktadır. Eğitilen model hem orijinal hem de yeniden oluşturulan diziyi kendi temsillerine dönüştürmektedir. Anormallik skoru temsiller arasındaki fark hesaplanarak bulunmaktadır.

Bir test zaman serisi için her adımında anomali skoru hesaplanmaktadır. Çalışma kapsamında kullanılan CL-TAD yöntemi, bu skorları belirleyebilmek, temsiller arasındaki mesafeyi hesaplamak için mesafeye dayalı olan Öklid fonksiyonu normalize edilerek kullanılmaktadır. Denklem 4.1’de normalize edilmiş Öklid fonksiyonu ( $D$ ) gösterilmektedir. Orijinal alt dizi kodlayıcı modülü üzerinden geçirildiğinde temsili  $U_i$  elde edilmektedir. Aynı zamanda maskelenmiş alt dizi, yeniden yapılandırma, dönüşüm ve kodlayıcı modülü ile sırasıyla işlenerek  $E_{iL+L-1}$  elde edilmektedir.

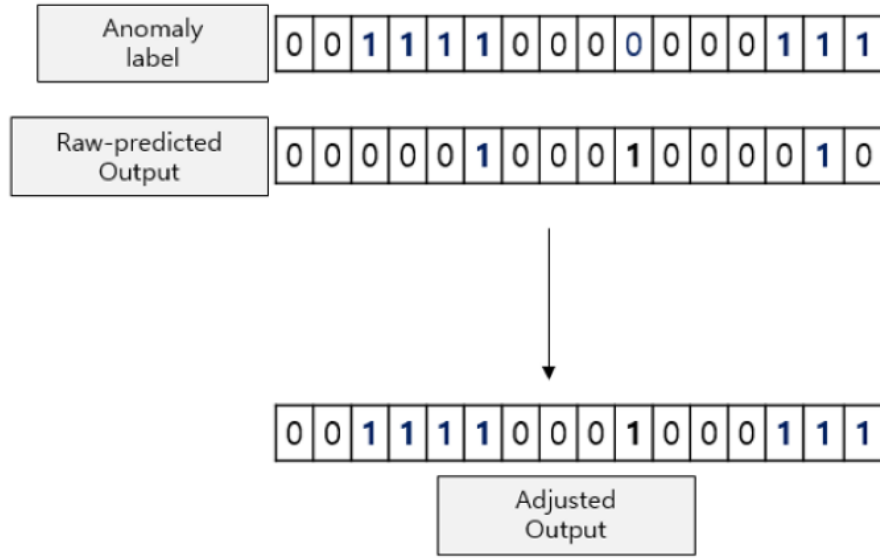
$$D(U_i, E_{iL+L-1}) = \left| \frac{U_i}{\|U_i\|} - \frac{E_{iL+L-1}}{\|E_{iL+L-1}\|} \right| \quad (4.1)$$

Uzunluk bilgisi 3 olan diziler için temsil oluşturma ve anomali skor hesaplama yapısı da Şekil 4.11’de gösterilmektedir.



Şekil 4.11. Temsil oluşturma ve anomali skor hesaplaması (Ngu vd., 2023)

Anomali skor hesaplamaları yapıldıktan bir eşik değeri belirlenerek anomali olup olmadığı belirlenmektedir. Ardından nokta ayarlama tekniği (the point adjustment technique) kullanılmaktadır. Bu teknik belirli bir zaman adımında anomali tespit edildiğinde sadece o adımı değil ilgili tüm zaman anomali olarak kabul edilmektedir. Şekil 4.12’de gösterildiği üzere ham tahmin edilen çıktı (raw-predicted output) kısmı eşik değeri kullanılarak tahmin edilen anomali sonuçlarını göstermektedir. Nokta ayarlama tekniği kullanıldıktan sonra oluşan sonuç ise ayarlanmış çıktı (adjusted output) olarak adlandırılan kısımdır. Uygulanan bu teknik dikkat edilmesi gereken tüm zaman penceresini anomali olarak düzelterek hata olasılığını azaltmaktadır ve anomali tespiti daha güvenilir hale gelmektedir.



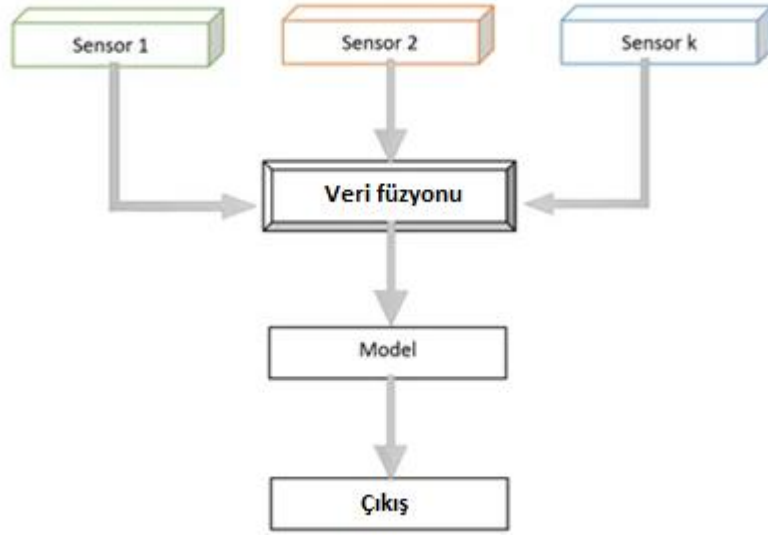
Şekil 4.12. Nokta ayarlama tekniği (Ngu vd., 2023)

#### 4.4. Füzyon (Fusion)

Farklı veri kaynaklarından gelen bilgilerin çeşitli yöntemler ile birleştirme işlemine füzyon denmektedir. Verilerin birleştirilme amacı daha kapsamlı ve güvenilir bilgi etmektir. Genellikle çok sensörlü ortamlarda kullanılmaktadır. Füzyon işlemlerinin farklı yöntemleri mevcuttur. Bunlar genel olarak aşağıdaki gibidir.

##### 4.4.1. Veri seviyesi füzyon (data level fusion)

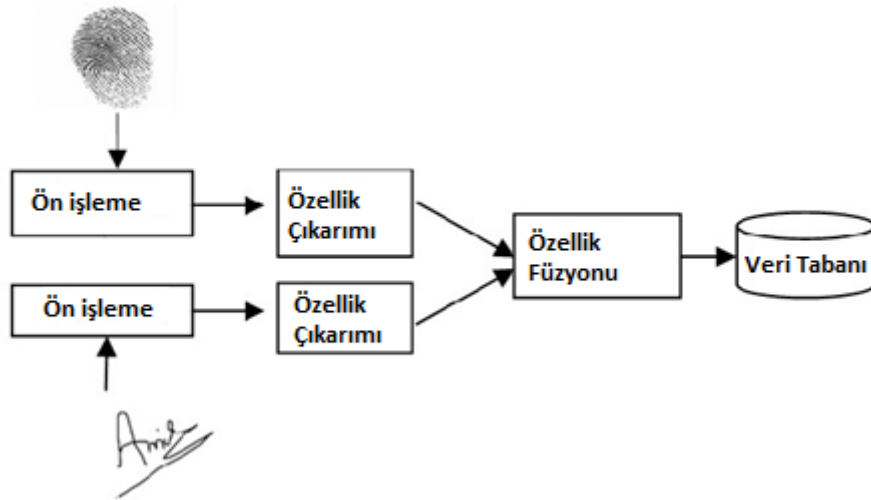
Şekil 4.13'deki gibi farklı kaynaklardan alınan ham verilerin birleştirilmesi ile oluşturulmaktadır. Veri füzyonu terimi doğrudan sensörlerden elde edilen verileri kullanmaktadır (Castanedo, 2013).



Şekil 4.13. Veri seviyesi füzyon modeli

#### 4.4.2. Özellik seviyesi füzyon (feature level fusion)

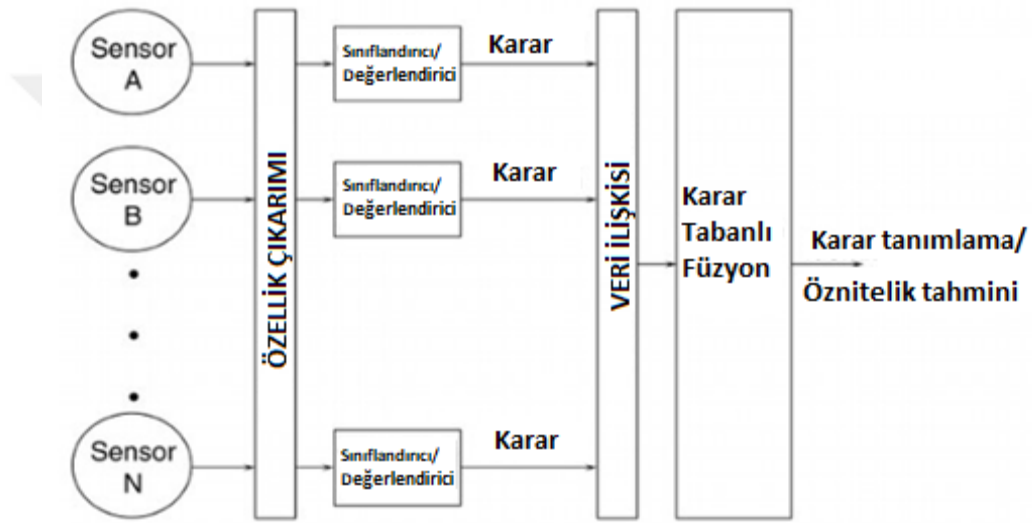
Şekil 4.14'deki gibi farklı kaynaklardan alınan verilerin öncelikle belirli özelliklerinin çıkarılıp ardından bu özelliklerin birleştirilmesi ile oluşturulmaktadır. Amacı her kaynaktan çıkarmış olduğu anlamlı özellikleri birleştirerek daha başarılı sonuç elde edebilmektir.



Şekil 4.14. Özellik seviyesi füzyon modeli (Leghari vd., 2018)

#### 4.4.3. Karar tabanlı füzyon (desicion level fusion)

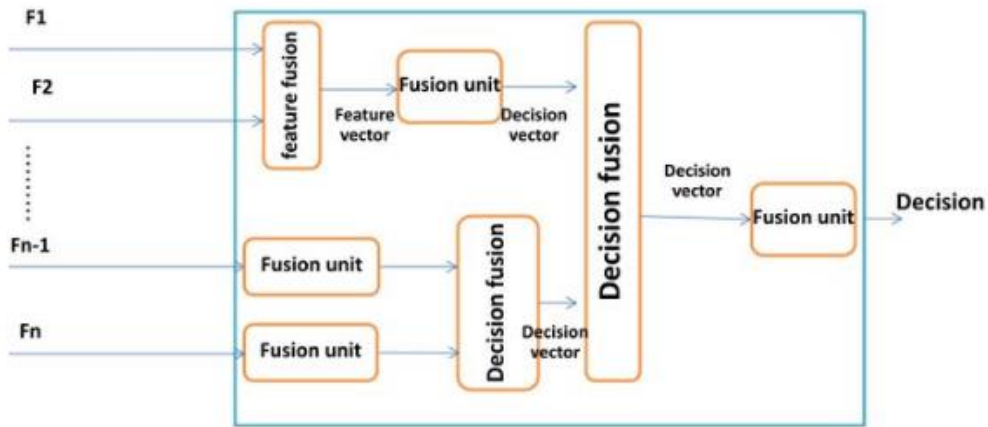
Şekil 4.15'te gösterildiği gibi farklı kaynaklardan gelen verilerin öncelikle özellik çıkarımı gerçekleştirilmektedir. Ardından yapılan karar sonuçlarına göre verilen kararlar birleştirilmektedir. Farklı kaynaklardan elde edilen kararların birbirinden bağımsız olduğunu ve bu bağımsız kararları birleştirerek bir sonuç elde etmeyi amaçlamaktadır.



Şekil 4.15. Karar tabanlı füzyon modeli (De Boer, 2002)

#### 4.4.4. Hibrit füzyon (hybrid fusion)

Hibrit füzyon Şekil 4.16'daki gibi diğer füzyon yöntemlerinin kombinasyonunu içeren ve bu doğrultuda karar verilmesini sağlayan yöntemdir. Diğer füzyon yöntemleri çeşitli seviyelerde yapılabilmektedir. Bu sayede performansın daha yüksek olması hedeflenmektedir.



Şekil 4.16. Hibrit füzyon modeli (Rashidi vd., 2014)

#### 4.5. Füzyon ve CL-TAD

Çalışma kapsamında kullanılan BVP, EDA ve ST fizyolojik sinyalleri öncelikle ayrı ayrı değerlendirilecek test edilmektedir. Ancak fizyolojik sinyal verilerinin aynı anda toplanması nedeniyle, bu verilerin bir arada kullanarak daha kapsamlı veri sağlamak ve daha başarılı sonuç elde edilebilmesi amaçlanmaktadır.

CL-TAD yöntemi verileri okuduktan sonra verileri normalize ederek 0-1 aralığına getirmektedir. Çalışma kapsamında öncelikle veri seti CL-TAD yöntemi kullanılarak test edilmektedir. Fizyolojik sinyallerin birlikte kullanılarak daha güvenilir sonuçlar elde edilebilmesi amacıyla bu yöntemle füzyon işlemi de eklenmiştir. Füzyon işleminin gerçekleştirilebilmesi için normalize edilip 0-1 aralığına getirilen veriler art arda eklenmektedir. Eğitim ve test için ayrılan veriler fizyolojik sinyallerin normalize edilmesi ve art arda eklenmesi ile oluşmaktadır.

## 5. BULGULAR VE TARTIŞMA

Yapılan çalışma kapsamında AKTIVES veri seti kullanılarak fizyolojik sinyaller ile anomali tespiti yapılması hedeflenmiş, çeşitli hastalıklara sahip olan çocuklarda stres tespiti yapılmıştır. Zaman serisi veriler için çeşitli yöntemler araştırılmış, bu kapsamda son yıllarda daha çok kullanılmaya başlanan karşılaştırmalı öğrenme yönteminin zaman serisi verilerde kullanıldığı görülmüştür. Birçok çalışmada daha çok görüntüler üzerinde kullanılan karşılaştırmalı öğrenme yönteminin etiketlenme problemi olan zaman serisi verilerde de başarılı olduğunu gösteren yeni çalışmalar yapılmaktadır. Yapılan çalışmalar incelendiğinde yeni ortaya çıkan CL-TAD yönteminin birçok veri setinde başarılı olduğu görülmektedir. Bu nedenle çalışma kapsamında CL-TAD yönteminin fizyolojik sinyaller üzerindeki başarısı test edilmiştir.

Veri setinde 25 çocuk için ayrı ayrı olacak şekilde BVP, EDA, ST ve uzmanlar tarafından her 10 saniyeye karşılık etiketlenmiş stres/stres yok, tepki/tepki yok verilerini içeren csv dosyaları bulunmaktadır. Fizyolojik sinyalleri içeren csv dosyalarında etiket bilgilerinin olmaması nedeniyle, her 10 saniyeye karşılık gelen etiket bilgileri de çoğunluk kontrolü ile csv dosyasına eklenmiştir.

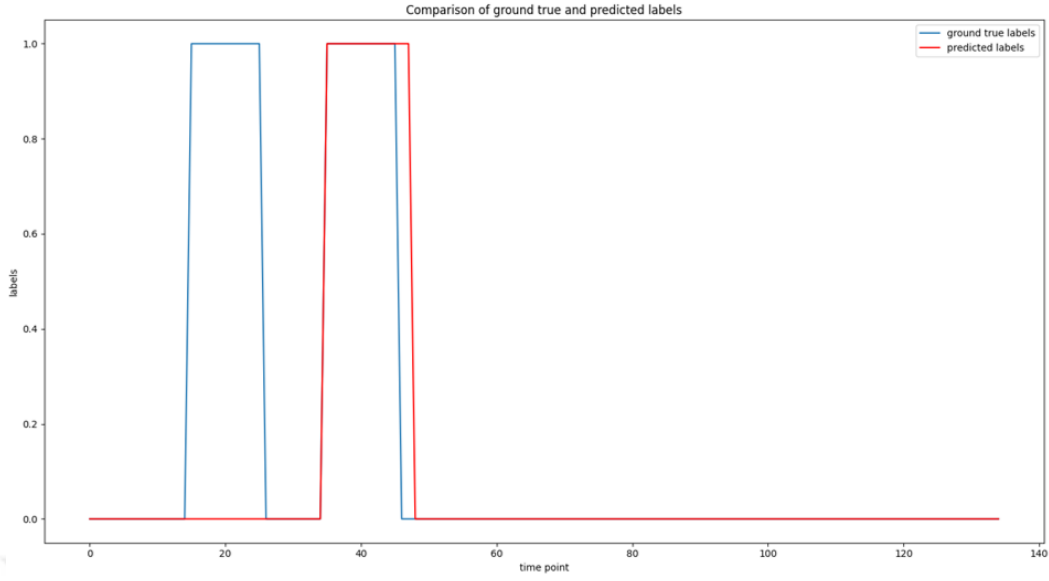
Öncelikle veriler genel olarak ele alınıp eğitim ve test sürecinden geçirilerek anomali tespiti yapılmıştır. Bu kapsamda 23 çocuğa ait BVP, EDA ve ST verileri kendi kategorilerinde birleştirilerek eğitim ve test sürecinden geçirilmiştir. Örneğin 23 çocuğa ait BVP verileri art arda eklenerek yeni bir csv dosyası oluşturulmuştur. Ardından eğitim için %70, test için ise %30 olacak şekilde ayrılmıştır. Her fizyolojik sinyal özelinde birleştirilen veriler ile anomali testi yapılmıştır. Tüm fizyolojik sinyaller için genel anomali tespiti yapıldığında ortaya çıkan doğruluk oranı Çizelge 5.1’de gösterilmektedir.

Çizelge 5.1. Genel BVP, EDA ve ST doğruluk oranları

	<b>BVP Doğruluk Oranı</b>	<b>EDA Doğruluk Oranı</b>	<b>ST Doğruluk Oranı</b>
<b>Genel</b>	85,7	72,3	83,5


Tüm veriler bir arada kullanılarak yapılan anomali tespiti sonrasında her kişinin stresli bir durum altında vereceği tepkilerin farklı olacağı düşünülerek kişiselleştirilmiş anomali tespitinin daha başarılı olacağı düşünülmüştür. Çünkü zorlu bir durum karşısında bazıları daha rahat davranırken, bazıları daha stresli olabilmektedir. Bu nedenle tüm veriler kullanılarak yapılan anomali tespiti sonrasında kişiselleştirilmiş anomali tespiti yapılmasına karar verilmiştir. Bu sayede savunulan durumun doğru sonuç verip vermediği gözlemlenmiştir. Her kişi için BVP, EDA ve ST verilerini içeren csv dosyaları öncelikle tek tek %70 oranında, test için ise %30 oranında ayrılmaktadır. Ardından CL-TAD yöntemi ile birlikte ilk olarak eğitim sürecinden geçmektedir. Eğitim bittikten sonra her dosya için eğitim bilgileri kaydedilmektedir ve kaydedilen bilgiler doğrultusunda anomali tespiti sürecinden geçmektedir. Eğitim ve test süreci gerçekleştirilirken 4 ve 8 numaralı çocuklar için oluşturulan dosyalardaki hatalı durumlar nedeniyle veri setinden bu çocukların verileri çıkarılmıştır.

Her çocuk için ayrı ayrı BVP, EDA ve ST verileri için çalıştırılan test sonucunda gerçekteki anomali durumu ile tahmin edilen anomali durumu için grafikler oluşturulmuştur. C01 olarak adlandırılan çocuğa ait BVP verileri için anomali tespiti yapıldığında ortaya çıkan grafik Şekil 5.1'deki gibidir. Mavi renklendirilen kısımlar incelendiğinde iki ayrı 10 saniyelik zaman için uzmanlar tarafından anomali olarak değerlendirildiği gösterilmektedir. Karşılaştırmalı öğrenme yöntemi ile anomali tespiti sonucunda sadece ikinci 10 saniyelik zaman aralığının doğru tahmin edilebildiği görülmekte ve anomali olarak değerlendirilmeyen 2 saniyenin de anomali olarak değerlendirildiği görülmektedir.




Şekil 5.1. C01 BVP için gerçek ve tahmin edilen etiket karşılaştırılması

C01 olarak adlandırılan çocuğa ait EDA verileri üzerinde anomali tespiti yapıldığında ise Şekil 5.2'de görüldüğü gibi bu sefer ilk 10 saniyelik zaman aralığında anomalinin doğru olarak tahmin edilebildiği, ikinci aralığın anomali olarak tahmin edilemediği görülmektedir. Yine anomali olmasına rağmen anomali olarak değerlendirilen 2 saniyelik veri olduğu da görülmektedir.



Şekil 5.2. C01 EDA için gerçek ve tahmin edilen etiket karşılaştırılması

C01 olarak adlandırılan çocuğa ait ST verileri üzerinde anomali tespiti yapıldığında Şekil 5.3'te görüldüğü gibi gerçekte anomali olan 2 ayrı 10 saniyelik zaman aralığının da başarılı bir şekilde anomali olarak tahmin edilebildiği görülmektedir. Ancak anomali olmamasına rağmen anomali olarak değerlendirilen alanlar diğer verilerdekine göre daha fazladır.



Şekil 5.3. C01 ST için gerçek ve tahmin edilen etiket karşılaştırılması

Kişiselleştirilmiş olarak BVP, EDA ve ST verileri üzerinden yapılan doğruluk (accuracy) oranları ise Çizelge 5.1'de gösterilmektedir. Ayrıca çizelgenin sonunda her doğruluk oranı için genel başarı ortalaması da hesaplanmaktadır.

Çizelge 5.2. Kişiselleştirilmiş BVP, EDA ve ST doğruluk oranları

Kişi	BVP Doğruluk Oranı	EDA Doğruluk Oranı	ST Doğruluk Oranı
C01	90,3	89,6	94,0
C02	100	100	100
C03	100	100	100
C06	100	100	100
C07	95,6	91,2	65,2


Çizelge 5.2. Kişiselleştirilmiş BVP, EDA ve ST doğruluk oranları

Kişi	BVP Doğruluk Oranı	EDA Doğruluk Oranı	ST Doğruluk Oranı
C09	100	100	100
C10	70,3	77,8	69,6
C11	91,9	91,1	91,2
C12	100	100	99,2
C13	83,3	89,5	99,1
C14	94,1	94,8	94,8
C15	87,5	90,8	90,0
C16	100	100	100
C17	94,1	91,9	91,9
C18	71,1	71,1	82,2
C19	100	100	100
C20	100	99,3	100
C21	100	100	100
C22	56,3	58,5	81,4
C23	85,9	86,7	86,7
C24	100	84,3	84,1
C25	100	100	99,2
<b>Genel Başarı</b>	<b>91,8</b>	<b>91,7</b>	<b>92,2</b>

Veri seti üzerindeki kişiselleştirilmiş doğruluk oranları yüzdesel olarak 56 ile 100 arasında seyretmektedir. Genel ortalamaya bakıldığında ise yaklaşık %92 başarı oranı ile kişiselleştirilmiş anomali tespitinin başarı olduğu görülmektedir.

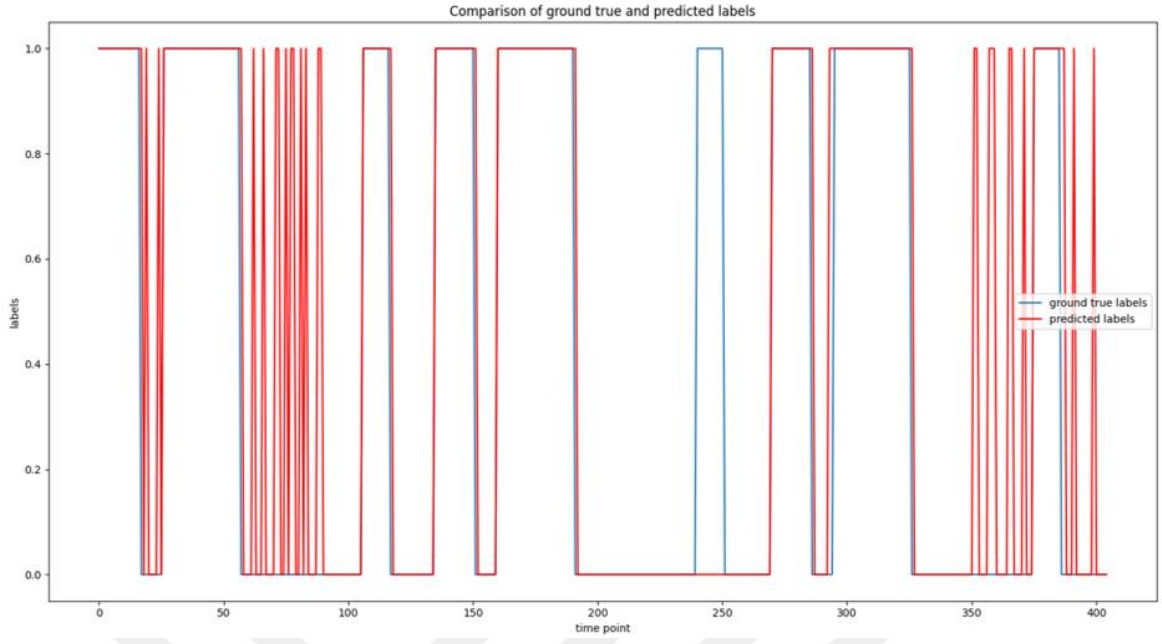
Çizelge 5.1 ile Çizelge 5.2 karşılaştırıldığında genel başarı oranlarındaki artış ile kişiselleştirilmiş anomali tespitinin savunulduğu gibi daha başarılı olduğu görülmektedir. Bu nedenle çalışma kapsamında kişiselleştirilmiş anomali tespitinin yapılması gerektiğine karar verilmiştir.

Füzyon işlemleri farklı kaynaklardan alınan veriler kullanılarak daha güvenilir olması ile ortaya çıkmaktadır. Bu nedenle çalışmanın ilerleyen süreçlerinde füzyon kullanılarak anomali tespitinin daha başarılı olacağı düşünülmüştür. Kişiselleştirilmiş anomali tespitinin başarılı çıkması ile birlikte, aynı şekilde her kişi özelinde BVP, EDA ve ST verilerinin bir arada kullanılarak daha başarılı olup olmayacağı test edilmiştir. Her kişi özelinde BVP, EDA ve ST verileri füzyon işlemine tutularak eğitim ve test sürecinden geçirilmiştir. Ayrıca test sonucunda gerçekteki anomali durumu ile tahmin edilen anomali durumu için grafikler oluşturulmuştur. C01 olarak numaralandırılan çocuğa ait fizyolojik sinyallerin füzyon işlemi sonrasında test edilmesi ile birlikte ortaya çıkan grafik Şekil 5.4'teki gibidir. Çıkan grafik ile birlikte anomali olarak sadece tek 10 saniyelik zaman aralığının doğru tahmin edilebildiği görülmektedir.



Şekil 5.4. C01 füzyon işlemi sonrası gerçek ve tahmin edilen etiket karşılaştırılması

C10 olarak numaralandırılan çocuk için füzyon uygulanarak yapılan anomali testi sonucunda ait grafik ise 5.5'teki gibidir. Bu grafikte de görüldüğü gibi neredeyse gerçekte anomali olan bütün alanlar anomali olarak tahmin edilmiştir. Ancak çok fazla alan içinde anomali olmamasına rağmen anomali olarak değerlendirilmiştir.



Şekil 5.5. C10 füzyon işlemi sonrası gerçek ve tahmin edilen etiket karşılaştırılması

Çizelge 5.3'te kişi özelinde füzyon işleminden geçtikten sonra ortaya çıkan doğruluk oranları gösterilmektedir. Füzyon sonrası ortaya çıkan sonuç ile füzyon öncesindeki sonuç karşılaştırıldığında genel başarı oranının birbirine yakın olduğu görülmektedir.

Çizelge 5.3. Füzyon sonrası doğruluk oranları

Kişi	Füzyon Sonrası Doğruluk Oranı
C01	86,2
C02	100
C03	100
C06	100
C07	76,3
C09	100
C10	88,9
C11	91,7
C12	100
C13	84,2
C14	95,1

Çizelge 5.3. Füzyon sonrası doğruluk oranları

<b>Kişi</b>	<b>Füzyon Sonrası Doğruluk Oranı</b>
C15	90,6
C16	99,6
C17	94,8
C18	83,7
C19	100
C20	100
C21	100
C22	70,6
C23	90,1
C24	91,3
C25	100
<b>Genel Başarı</b>	<b>92,5</b>

Karşılaştırmalı öğrenme yöntemi kullanılarak ortaya atılan CL-TAD modeli ile yapılan anomali tespiti doğruluk oranlarına bakıldığında çalışmanın başarılı olduğu söylenebilmektedir. Fizyolojik sinyaller kullanılarak yapılan anomali tespiti kişiselleştirilmiş olduğunda genelle kıyaslandığında daha başarılı olmaktadır. Ayrıca füzyon işlemi kullanılarak farklı kaynaklardan elde edilen fizyolojik sinyallerin birleştirilerek ortaya çıkan sonucun savunulduğu gibi daha başarılı olduğu görülmektedir.

Veri setinde yapılan etiketlemeler 3 ayrı uzman tarafından yapılmaktadır. Ancak yapılan çalışma kapsamında 3 uzmandan en az 2'sinin stresli dediği durumlar anomali olarak etiketlenmiştir. Bu nedenle aslında stresli olarak değerlendirilmeyen verilerin stresli olma ihtimali göz ardı edilmektedir. Ortaya çıkan sonuçlar değerlendirildiğinde, özellikle de anomali olarak etiketlenmeyen ancak anomali olarak değerlendirilen sonuçların aslında doğru olarak tahmin edilmiş olabileceği göz ardı edilmemelidir. Kedi köpek ayrımı gibi birbirinden kesin olarak ayırt edilebilen veriler üzerinde denendiğinde performans daha net ölçülebilmektedir. Ancak veri setindeki etiketler uzmanların değerlendirmeleri sonucunda oluşmuştur. Bu nedenle de çalışma sadece bu etiketler ile karşılaştırıldığında elde edilen performansı göstermektedir.

## 6. SONUÇ VE ÖNERİLER

Teknolojinin gelişmesi ile daha kolay elde edilebilen fizyolojik sinyaller günümüzde birçok çalışmada, özellikle sağlık alanında hastalıkları önlemek veya tespit edebilmek amacıyla kullanılmaktadır. Kullanılan veriler üzerinden tahminler yapılabilmesi ve doğruluğunun kontrol edilebilmesi için uzmanlar tarafından verilerin etiketlenmesine ihtiyaç duyulmaktadır. Ancak 2020 yılından itibaren karşılaştırmalı öğrenme yönteminin bu problemi çözebilmek adına daha çok kullanılmaya başlanması yeni çalışmaların önünü açmaktadır. Literatür araştırması yapıldığında karşılaştırmalı öğrenme yönteminin temel alınarak özellikle etiketsiz veriler üzerinde sorunları çözebilmesi adına birçok model görülmektedir. Bu modeller diğer çalışmalara örnek olmakla birlikte, daha iyi çözümler bulunabilmesi adına da yardımcı olmaktadır.

Çalışma kapsamında etiketsiz fizyolojik sinyaller üzerinde anomali tespiti yapılmaktadır. Anomali olarak değerlendirilen stres durumunun tespit edilebilmesi için karşılaştırmalı öğrenme tabanlı olarak yeni sunulan CL-TAD modeli seçilmiştir. Modelin yeni olması ve birçok veri setinde denendiğinde başarılı oranlar vermesi tercih sebebi olmaktadır. Tez kapsamında kullanılan CL-TAD modeli AKTIVES veri seti üzerinde de başarılı olmuştur.

Bireylerin yaşamış oldukları durumlar için vermiş olduğu tepkiler değişebildiği için kişiselleştirilmiş anomali tespiti yapılmasının daha doğru olacağı savunulmuş, genel ve kişiselleştirilmiş anomali tespiti doğruluk oranları karşılaştırıldığında da doğru olduğu görülmüştür. Elde edilen fizyolojik sinyallerin çeşitliliğinin füzyon işlemine de uygun olması ile birlikte daha güvenilir ve başarılı sonuçlar elde edilebileceği düşünülmüş ve doğruluk oranları karşılaştırıldığında daha başarılı olduğu gözlemlenmiştir.

AKTIVES veri setinin çeşitli hastalıklara sahip çocukların oyun oynarken akıllı bileklik aracılığı ile elde edilen veriler olması, yapılan çalışmadaki stres tahmininin oyuna

entegre edilebilmesine olanak sağlamaktadır. Her kiři özelinde akıllı bileklikten alınan verilerin 1-2 dakika boyunca toplanıp eğitilip ardından geçen süreler de anomali tespiti yapılabilir olacaktır.

Anomali tespitinin genel bir konu ve çeşitli alanlarda kullanılabilir olması nedeniyle kişiselleştirilerek kullanılan modelin gelecek çalışmalarda federe öğrenme (federated learning) yönteminin önünü de açmaktadır. Federe öğrenme yönteminde kullanıcı gizliliği önemlidir. Kullanıcılardan alınan veriler kim olduğu bilinmeden tutulur ve o kiři özelinde eğitilmektedir. Verilerin tamamının toplanıp tek bir yerde eğitilerek herkes için kullanılması söz konusu değildir. Tez kapsamında yapılan çalışmada aynı şekilde uygulanarak kişiselleştirilmiş stres takibi yapılabilmesine olanak sağlamaktadır.

## KAYNAKLAR DİZİNİ

- Castanedo, F. (2013). A review of data fusion techniques. *The Scientific World Journal*, 2013, 1-19. <https://doi.org/10.1155/2013/704504>
- Chen, L., Zhao, Y., Ye, P., Zhang, J., & Zou, J. (2017). Detecting driving stress in physiological signals based on multimodal feature analysis and kernel classifiers. *Expert Systems with Applications*, 85, 279-291. <https://doi.org/10.1016/j.eswa.2017.01.040>
- Chen, X., Fan, H., Girshick, R., & He, K. (2020). Improved baselines with momentum contrastive learning. arXiv preprint arXiv:2003.04297.
- Coşkun, B., Ay, S., Erol Barkana, D., Bostancı, H., Uzun, İ., Oktay, A. B., Tuncel, B., & Tarakci, D. (2023). A physiological signal database of children with different special needs for stress recognition. *Scientific Data*, 10(1). <https://doi.org/10.1038/s41597-023-02272-2>
- Darban, Z. Z., Webb, G. I., Pan, S., & Salehi, M. (2023). CARLA: A Self-supervised Contrastive Representation Learning Approach for Time Series Anomaly Detection. arXiv preprint arXiv:2308.09296.
- de Boer, R. C. (2002). A Generic architecture for fusion-based intrusion detection systems (Doctoral dissertation, Erasmus Universiteit).
- Desarkar, A., & Das, A. (2017). Big-data analytics, machine learning algorithms and scalable/Parallel/Distributed algorithms. *Studies in Big Data*, 159-197. [https://doi.org/10.1007/978-3-319-49736-5\\_8](https://doi.org/10.1007/978-3-319-49736-5_8)
- El Naqa, I., & Murphy, M. J. (2015). What is machine learning? *Machine Learning in Radiation Oncology*, 3-11. [https://doi.org/10.1007/978-3-319-18305-3\\_1](https://doi.org/10.1007/978-3-319-18305-3_1)

## KAYNAKLAR DİZİNİ

- González-González, C. S., Gómez del Río, N., Toledo-Delgado, P. A., & García-Peñalvo, F. J. (2021). Active game-based solutions for the treatment of childhood obesity. *Sensors*, 21(4), 1266. <https://doi.org/10.3390/s21041266>
- Gu, H., Wang, Y., Hong, S., & Gui, G. (2019). Blind channel identification aided generalized automatic modulation recognition based on deep learning. *IEEE Access*, 7, 110722-110729. <https://doi.org/10.1109/access.2019.2934354>
- Han, N., Gao, S., Li, J., Zhang, X., & Guo, J. (2018). Anomaly detection in health data based on deep learning. *2018 International Conference on Network Infrastructure and Digital Content (IC-NIDC)*. <https://doi.org/10.1109/icnidc.2018.8525737>
- Hao, X., Zhang, G., & Ma, S. (2016). Deep learning. *International Journal of Semantic Computing*, 10(03), 417-439. <https://doi.org/10.1142/s1793351x16500045>
- He, F., Karami Olia, P., Jamili Oskouei, R., Hosseini, M., Peng, Z., & BaniRostam, T. (2021). Applications of deep learning techniques for pedestrian detection in smart environments: A comprehensive study. *Journal of Advanced Transportation*, 2021, 1-14. <https://doi.org/10.1155/2021/5549111>
- He, K., Fan, H., Wu, Y., Xie, S., & Girshick, R. (2020). Momentum contrast for unsupervised visual representation learning. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. <https://doi.org/10.1109/cvpr42600.2020.00975>
- Jaiswal, A., Babu, A. R., Zadeh, M. Z., Banerjee, D., & Makedon, F. (2020). A survey on contrastive self-supervised learning. *Technologies*, 9(1), 2. <https://doi.org/10.3390/technologies9010002>

## KAYNAKLAR DİZİNİ

- Khosla, P., Teterwak, P., Wang, C., Sarna, A., Tian, Y., Isola, P., ... & Krishnan, D. (2020). Supervised contrastive learning. *Advances in neural information processing systems*, 33, 18661-18673.
- Knox, M., Lentini, J., Cummings, T. S., McGrady, A., Whearty, K., & Sancrant, L. (2011). Game-based biofeedback for paediatric anxiety and depression. *Mental health in family medicine*, 8(3), 195.
- Kushki, A., Fairley, J., Merja, S., King, G., & Chau, T. (2011). Comparison of blood volume pulse and skin conductance responses to mental and affective stimuli at different anatomical sites. *Physiological Measurement*, 32(10), 1529-1539. <https://doi.org/10.1088/0967-3334/32/10/002>
- Lea, C., Flynn, M. D., Vidal, R., Reiter, A., & Hager, G. D. (2017). Temporal Convolutional networks for action segmentation and detection. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. <https://doi.org/10.1109/cvpr.2017.113>
- Leghari, M., Memon, S., & Chandio, A. A. (2018). Feature-level fusion of fingerprint and online signature for multimodal biometrics. *2018 International Conference on Computing, Mathematics and Engineering Technologies (iCoMET)*. <https://doi.org/10.1109/icomet.2018.8346358>
- Le-Khac, P. H., Healy, G., & Smeaton, A. F. (2020). Contrastive representation learning: A framework and review. *IEEE Access*, 8, 193907-193934. <https://doi.org/10.1109/access.2020.3031549>
- Li, F., Chang, H., Jiang, M., & Su, Y. (2022). A contrastive learning framework for ECG anomaly detection. *2022 7th International Conference on Intelligent Computing and Signal Processing (ICSP)*. <https://doi.org/10.1109/icsp54964.2022.9778634>

**KAYNAKLAR DİZİNİ**

- Lin, I., Fan, S., Lu, Y., Lee, C., Wu, K., & Ji, H. (2015). Exploring the blood volume amplitude and pulse transit time during anger recall in patients with coronary artery disease. *Journal of Cardiology*, 65(1), 50-56. <https://doi.org/10.1016/j.jjcc.2014.03.012>
- Liu, M., Li, L., Hao, S., Zhu, Y., & Zhao, D. (2023). Soft contrastive learning with Q-irrelevance abstraction for reinforcement learning. *IEEE Transactions on Cognitive and Developmental Systems*, 15(3), 1463-1473. <https://doi.org/10.1109/tcds.2022.3218940>
- Liu, X. (2021). Model construction of using physiological signals to detect mental health status. *Journal of Healthcare Engineering*, 2021, 1-8. <https://doi.org/10.1155/2021/8544750>
- Nawaz, M., & Ahmed, J. (2021). Anomaly detection and classification of physiological signals in iot- Based healthcare framework. <https://doi.org/10.21203/rs.3.rs-540398/v2>
- Ngu, H. C., & Lee, K. M. (2023). CL-TAD: A contrastive-learning-Based method for time series anomaly detection. *Applied Sciences*, 13(21), 11938. <https://doi.org/10.3390/app132111938>
- Ongsulee, P. (2017). Artificial intelligence, machine learning and deep learning. *2017 15th International Conference on ICT and Knowledge Engineering (ICT&KE)*. <https://doi.org/10.1109/ictke.2017.8259629>
- Picton, P. (1994). What is a neural network? *Introduction to Neural Networks*, 1-12. [https://doi.org/10.1007/978-1-349-13530-1\\_1](https://doi.org/10.1007/978-1-349-13530-1_1)

**KAYNAKLAR DİZİNİ**

- Rashidi, A., Ahmadi, K. D., & Jafari, A. (2014). Multi-level fusion to improve threat pattern recognition in cyber defense. *Journal of Mathematics and Computer Science*, 08(04), 398-410. <https://doi.org/10.22436/jmcs.08.04.08>
- Ratnavale, S., Hepp, C., Doerry, E., & Mihaljevic, J. R. (2022). A sliding window approach to optimize the time-varying parameters of a spatially-explicit and stochastic model of COVID-19. *PLOS Global Public Health*, 2(9), e0001058. <https://doi.org/10.1371/journal.pgph.0001058>
- Rochette, L., Dogon, G., & Vergely, C. (2023). Stress: Eight decades after its definition by Hans Selye: “Stress is the spice of life”. *Brain Sciences*, 13(2), 310. <https://doi.org/10.3390/brainsci13020310>
- Roy, S., & Etemad, A. (2021). Self-supervised contrastive learning of multi-view facial expressions. *Proceedings of the 2021 International Conference on Multimodal Interaction*. <https://doi.org/10.1145/3462244.3479955>
- Song, X., Yang, D., Wang, Y., Wang, H., Wang, J., & Zheng, B. (2023). TransFusion model fusion mechanism based on transformer for traffic flow prediction. *Journal of Database Management*, 34(3), 1-14. <https://doi.org/10.4018/jdm.325353>
- Torky, A. A., & Aburawwash, A. A. (2018). A Deep Learning Approach to Automated Structural Engineering of Prestressed Members. *International Journal of Structural and Civil Engineering Research*, 347–352. <https://doi.org/10.18178/ijscer.7.4.347-352>
- Wang, R., Liu, C., Mou, X., Gao, K., Guo, X., Liu, P., Wo, T., & Liu, X. (2023). Deep contrastive one-class time series anomaly detection. *Proceedings of the 2023 SIAM International Conference on Data Mining (SDM)*, 694-702. <https://doi.org/10.1137/1.9781611977653.ch78>

## KAYNAKLAR DİZİNİ

World Health Organization (WHO). (2023, February 21). *What is stress?* <https://www.who.int/news-room/questions-and-answers/item/stress>

Yamashita, R., Nishio, M., Do, R. K., & Togashi, K. (2018). Convolutional neural networks: An overview and application in radiology. *Insights into Imaging*, 9(4), 611-629. <https://doi.org/10.1007/s13244-018-0639-9>

