



**SUALTI OBJELERİNİN SINIFLANDIRILMASINDA YENİ BİR
YAKLAŞIM OLARAK MATEMATİKSEL DÖNÜŞÜM VE DERİN
ÖĞRENME YÖNTEMLERİNİN UYGULANMASI**

Aybüke CİVRİZOĞLU BUZ

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2021

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Aybüke CİVRİZOĞLU BUZ

22 /06/2021

SUALTI OBJELERİNİN SINIFLANDIRILMASINDA YENİ BİR YAKLAŞIM OLARAK MATEMATİKSEL DÖNÜŞÜM VE DERİN ÖĞRENME YÖNTEMLERİNİN UYGULANMASI

(Yüksek Lisans Tezi)

Aybüke CİVRİZOĞLU BUZ

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2021

ÖZET

Sound Navigation and Ranging (Sonar), ses dalgalarını kullanarak nesnelere ait boyut, uzaklık, yön ve diğer bilgilerin tespit edilmesi için kullanılan bir sistemdir. Denizaltı petrol aramalarında, deniz tabanı haritalamalarında, balık sürülerinin takibinde, batıkların ve enkazların tespitlerinde ve en önemlisi mayınların, mayınlara şekil ve yapı olarak çok benzeyen kayalar gibi diğer nesnelerin tespitlerinde yaygın olarak kullanılmaktadır. Sonar sinyallerinin tanımlanması ve sınıflandırılması için kullanılması gereken öznitelik çıkarımı, en uygun algoritmaların seçimi ve bu algoritmaların hiperparametre optimizasyonu çalışmaları üzerinde uzun yıllardan beri çalışılan bilimsel problemler olarak karşımıza çıkmaktadır. Bu çalışmada, klasik makine öğrenimi algoritmaları ve öznitelik çıkarma süreçleri yerine, yenilikçi bir yaklaşımla Gramian Açısıl Alan (GAA, GATA, GAFA), Markov Geçiş Alanı (MGA) ve Tekrarlanma Grafiği (TG) olmak üzere üç farklı matematiksel dönüşüm yönteminin kullanılması ile tek boyutlu sonar verisinin görüntü formatında temsili önerilmiştir. Verinin görüntü formatında temsil edilmesi sayesinde klasik makine öğrenme algoritmaları yerine Evrişimli Sinir Ağı (ESA) Algoritmaları kullanılmasına imkân sağlanmıştır. Önerilen yenilikçi yöntem kapsamında, matematiksel dönüşümler kullanılarak elde edilen iki boyutlu görüntülerin oluşturduğu yeni veri seti ile başarımlar artırma teknikleri ve farklı evrişimli sinir ağı mimarileri kullanılarak oluşturulan dört farklı modelin başarımları test edilmiştir. Başarımların artırımı için verilerde; Tekil Değer Ayırımı (TDA) ile veriye ait en dikkat çekici özelliklerin bulunması ve Görüntü Birleştirme yöntemleri ile üç farklı dönüşüm yönteminden elde edilen görüntülerin tek bir görüntünün üç kanalına (KYM) verilmesi ile daha fazla özelliğe sahip yeni verilerin elde edilmesi sağlanmıştır. Üretilen modellerin performans sonuçları, literatürde incelenen aynı veri seti ile yapılan diğer çalışmalar ve bu çalışmada verinin temsiline değıştirilmesinden önce çalışılan klasik algoritmalar ile elde edilen sonuçlar bilinen metrikler kullanılarak karşılaştırılmıştır. Bu sonuçlar ışığında, önerilen yenilikçi yaklaşımın, literatürde incelenen aynı veri seti ile yapılmış çalışmalar arasında tespit edilen en iyi sonuçları verdiği belirlenmiştir.

Bilim Kodu : 92432
Anahtar Kelimeler : MGA, GAA, TG, Sonar, Derin Öğrenme
Sayfa Adedi : 72
Danışman : Dr. Uraz YAVANOĞLU
İkinci Danışman : Dr. Mustafa Umut DEMİREZEN

APPLICATION OF MATHEMATICAL TRANSFORMATION AND DEEP LEARNING
METHODS AS A NEW APPROACH TO CLASSIFICATION OF UNDERWATER
OBJECTS

(M. Sc. Thesis)

Aybüke CİVRİZOĞLU BUZ

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2021

ABSTRACT

Sound Navigation and Ranging (Sonar) is a system used to detect size, distance, direction and other information about objects using sound waves. It is widely used in submarine oil exploration, seafloor mapping, tracking fish shoals, detecting shipwrecks and debris, and most importantly detecting mines and other objects such as rocks that are very similar in shape and structure to mines. Feature extraction, which should be used for the identification and classification of sonar signals, the selection of the most appropriate algorithms, and the hyperparameter optimization of these algorithms are scientific problems that have been studied for many years. In this study, instead of classical machine learning algorithms and feature extraction processes, with an innovative approach; The representation of one-dimensional sonar data in image format is proposed by using three different mathematical transformation methods: Gramian Angular Field (GAA, GATA, GAFA), Markov Transition Field (MGA) and Repetition Graph (TG). Thanks to the representation of the data in image format, it is possible to use Convolutional Neural Network (ESA) Algorithms instead of classical machine learning algorithms. Within the scope of the proposed innovative method, the performance of four different models created by using the new data set created by 2D images obtained by using mathematical transformations, performance enhancement techniques and different convolutional neural network architectures were tested. In the data for performance increase; It has been ensured that the most remarkable features of the data are found with Single Value Decomposition (TDA), and new data with more features are obtained by transferring the images obtained from three different transformation methods with Image Merging methods to three channels (RGB) of a single image. The performance results of the models produced, other studies with the same data set examined in the literature, and the results obtained with the classical algorithms studied before changing the representation of the data in this study were compared using well-known metrics. In the light of these results, it was determined that the proposed innovative approach provided the best results among the studies conducted with the same data set examined in the literature.

Science Code : 92432

Key Words : MTF, GAF, RP, Sonar, Deep Learning

Page Number : 72

Supervisor : Dr. Uraz YAVANOĞLU

Co-Supervisor : Dr. Mustafa Umut DEMİREZEN

TEŞEKKÜR

Bu tez çalışmasında yardımlarını esirgemeyen ve bana yol gösterip her konuda destek olan, değerli bilgilerini ve zamanını benimle paylaşarak tez çalışmamda çok emeği olan saygıdeğer danışmanım Dr. Uraz YAVANOĞLU'na; sürecin en başından beri engin bilgilerini bana aktararak gerçekleştirdiğimiz çalışma konusunda her şeyi bana öğretene, ufkumu açarak bana her durumda destek olan, tüm değerli bilgileri ve tecrübeleri ile bana yol göstererek çalışmama yön veren, bu tezin tamamlanmasında çok büyük emeği olan akıl hocam, eş danışmanım Dr. Mustafa Umut DEMİREZEN'e teşekkürlerimi ve saygılarımı sunarım.

Hayatım boyunca sevginin, saygının kıymetini bilecek şekilde beni yetiştiren ve her konuda desteklerini yanımda hissettiğim çok değerli ailem; annem ve babam Şükrü – Birsen CİVRİZOĞLU'na, ablam Gizem ESKİ, eşi Arif Mutlu ESKİ ve yeğenim Elif Duru ESKİ'ye sonsuz sevgilerimi ve teşekkürlerimi sunarım.

Eğitim ve tez hazırlık sürecimin en başından beri her konuda desteğini yanımda hissettiğim, fikirleri ve yardımları ile beni hep daha iyiye yönlendiren, tez çalışmamı tamamlamamda çok büyük emeği olan çok değerli eşim Ümit Yasin BUZ'a desteği, sevgisi ve sabrı için tüm kalbimle teşekkürlerimi sunarım.

Çalışmamın en başında bana fikir veren ve çalışmalarım boyunca hiçbir yardımı ve desteği esirgemeyen çok değerli yöneticim Özgür ÖZUĞUR'a, çok değerli desteği için takım liderim Örsan AKBABA'ya teşekkürlerimi sunarım.

Çalışmalarım boyunca, gerek çalışmalarım konusunda gerekse manevi destekleri ile sürekli yanımda olan çok değerli çalışma arkadaşlarım Halime YAZĞAN, Gözde BOZTEPE KARATAŞ, İrem KAYA, Elif GÜLDİKEN, Gözde KOCA'ya, fikirleri ve desteği ile ufkumu genişletip, her zaman yanımda olan çok değerli Z. Bilinç SERİNTUNA'ya ve adlarını burada sayamadığım çalışmamda desteği olan herkese destekleri ve yardımları için teşekkürlerimi sunarım.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI.....	5
3. VERİ SETİ.....	13
4. KULLANILAN YÖNTEMLER VE METODOLOJİ.....	17
4.1. Kullanılan Makine Öğrenmesi Yöntemleri.....	21
4.1.1. Destek vektör makineleri algoritması	21
4.1.2. Doğrusal ayırmacılık analizi algoritması.....	23
4.1.3. Lojistik regresyon algoritması	24
4.1.4. GaussianNB algoritması	25
4.1.5. Karar ağacı algoritması.....	26
4.1.6. Rassal orman algoritması.....	28
4.1.7. K-En yakın komşu algoritması	29
4.2. Sensör Verisi – Görüntü Dönüşümü Yaklaşımı.....	30
4.2.1. Gramian açısal alan dönüşümü	31
4.2.2. Markov geçiş alanı dönüşümü	33
4.2.3. Tekrarlanma grafiği dönüşümü.....	34

	Sayfa
4.3. Tekil Değer Ayırışımı Yöntemi	36
4.4. Dönüştürülmüş Görüntü Verisinin Birleştirilmesi.....	37
4.5. Evrişimli Sinir Ağı Mimarisi	38
5. ÖNERİLEN YÖNTEM VE DENEYSEL DOĞRULAMA	49
6. PERFORMANS ANALİZİ VE TARTIŞMA.....	55
7. SONUÇ VE ÖNERİLER.....	61
KAYNAKLAR.....	65

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Literatürdeki yöntemlere ait karşılaştırmalı sonuç tablosu.....	10
Çizelge 6.1. Sonar sinyallerinin görüntü dönüşümü öncesi klasik makine öğrenme algoritmaları ile sınıflandırma sonuçları.....	57
Çizelge 6.2. Sensör verisi görüntü dönüşümü yöntemi ile elde edilen yeni veri seti İle ESA mimarisine ait en iyi sonuçlar	57
Çizelge 6.3. Sensör verisi görüntü dönüşümü yöntemi sonrası görüntü birleştirme yöntemleri ile elde edilen yeni veri seti ile ESA mimarisine ait en iyi sonuçlar	57
Çizelge 6.4. Sensör verisi görüntü dönüşümü ve tekil değer ayrışımı yöntemi ile elde edilen yeni veri seti ile ESA mimarisine ait en iyi sonuçlar	58
Çizelge 6.5. Sensör verisi görüntü dönüşümü ve tekil değer ayrışımı yöntemi ve görüntü birleştirme teknikleri ile elde edilen yeni veri seti ile ESA mimarisine ait en iyi sonuçlar	58

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Bir adet silindirik mayın ve kaya nesnelerinden dönen sinyal değeri	14
Şekil 3.2. Mayın hedefleri için ölçüm yapılan frekans bandına karşılık gelen sinyal dönüş değerleri	14
Şekil 3.3. Kaya hedefleri için ölçüm yapılan frekans bandına karşılık gelen sinyal dönüş değerleri	15
Şekil 4.1. Önerilen birinci yönteme ait akış diyagramı	18
Şekil 4.2. Önerilen ikinci yönteme ait akış diyagramı	19
Şekil 4.3. Önerilen üçüncü yönteme ait akış diyagramı	20
Şekil 4.4. Önerilen dördüncü yönteme ait akış diyagramı	21
Şekil 4.5. Destek vektör makineleri algoritması (DVM)	22
Şekil 4.6. Destek vektör makineleri algoritması (DVM)	23
Şekil 4.7. Lojistik regresyon algoritması (LR)	24
Şekil 4.8. Gaussian NB algoritması.	26
Şekil 4.9. Karar ağacı algoritması (KAA)	27
Şekil 4.10. Rassal orman algoritması (RO)	28
Şekil 4.11. K-En yakın komşu algoritması (K-EYK)	30
Şekil 4.12. Gramian açısal alan dönüşüm yöntemi	33
Şekil 4.13. Markov geçiş alanı dönüşümü	34
Şekil 4.14. Tekrarlanma grafiği dönüşüm yöntemi	36
Şekil 4.15. Örnek bir evrişimli sinir ağı mimari yapısı.....	38
Şekil 4.16. Örnek bir evrişim katmanı yapısı	39
Şekil 4.17. Örnek bir havuzlama katmanı yapısı	40
Şekil 4.18. Örnek bir tam bağlı katman yapısı.....	41

Şekil	Sayfa
Şekil 4.19. ReLU aktivasyon fonksiyon grafiği.....	43
Şekil 4.20. Sigmoid aktivasyon fonksiyon grafiği.....	44
Şekil 5.1. Önerilen birinci yönteme ait ESA mimarisi	51
Şekil 5.2. Önerilen ikinci yönteme ait ESA mimarisi.....	52
Şekil 5.3. Önerilen üçüncü yönteme ait ESA mimarisi	53
Şekil 5.4. Önerilen son yönteme ait ESA mimarisi	53
Şekil 6.1. Performans metrikleri	55

SİMGELER VE KISALTMALAR

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

Simgeler

Açıklamalar

db

Desibel

Kısaltmalar

Açıklamalar

ADAM

Adaptif Moment Tahmini

CNN

Convolutional Neural Network

DAA

Doğrusal Ayrımcılık Analizi

DVM

Destek Vektör Makineleri

ESA

Evrişimli Sinir Ağı Mimarisi

GAA

Gramian Açısal Alan

GAF

Gramian Angular Field

GAFA

Gramian Açısal Fark Alanı

GATA

Gramian Açısal Toplam Alanı

GNB

Gaussian Naive Bayes

KAA

Karar Ağacı Algoritması

KYM

Kırmızı-Yeşil-Mavi

K-EYK

K-En Yakın Komşu

LR

Lojistik Regresyon

MGA

Markov Geçiş Alanı

MTF

Markov Transition Field

ReLU

Rectified Linear Unit

RO

Rassal Orman

RP

Recurrence Plot

TDA

Tekil Değer Ayrışımı

TG

Tekrarlanma Grafiği

1. GİRİŞ

Son yıllarda sualtı dünyasının keşfindeki gelişmeler ile sualtındaki nesnelerin ve sualtı hedeflerinin tespiti, tespitinden sonra sınıflandırılması, sivil ve askeri amaçlı uygulamalarda önemli bir yere sahip olmaya başlamıştır. Sonar (Sound Navigation and Ranging), ses dalgalarını kullanarak cisimlerin boyutu, uzaklığı ve yapıları hakkında bilgi sahibi olunabilmesi için kullanılan bir sistemdir [1]. Sonar sistemleri başlangıçta deniz harpleri için geliştirilmeye başlanmış olsa da günümüzde petrol ve maden aramalarında, özellikle çıkarma gemileri için deniz tabanı haritalamalarında, sivil hayatta balıkçılık için avlanma bölgelerindeki balık sürülerinin tespitinde, dalga ve akıntıların ölçülmesinde, deniz dibindeki enkazların bulunmasında ve sualtı arama kurtarma çalışmalarında kullanılmaktadır [2]. Ülkelerin deniz güvenliğini sağlaması hem savaş hem de barış dönemlerinde büyük öneme sahip olmuştur. Sualtında bulunan hedeflerin ve mayınların tespiti kıyı emniyetini korumanın yanı sıra, gemi çıkarmalarını ve liman kontrollerini sağlıklı bir şekilde yapabilmek için önemlidir. Sonar alanında teknolojinin gelişmesi ile birlikte sinyallerin ve buna bağlı olarak görüntülerin kalitesi ve özellikleri arttığından dolayı daha geniş imkânlar sunulmaya başlanmıştır. Ancak elde edilen verilerin ülkeler için önemi ve gizliliği, gerçek görüntü ve sinyaller ile mayın ve benzeri nesne tespiti çalışmalarını zorlaştırmaktadır. Bu konuda açık veri setlerinin ve kaynakların az olmasından dolayı literatürde yayınlanmış makine öğrenmesi tabanlı çalışmalar sınırlı sayıdadır.

Sualtındaki ortam değişkenliği, kirlilik oranı sinyal üzerine eklenen gürültülere neden olurken, mayın çeşitliliğinin fazlalığı, kaya, enkaz gibi sualtında bulunan diğer nesnelerin şekil olarak mayınlara benzerliği de göz önüne alındığında mayın objelerinin yapay zekâ algoritmaları ile tespitinin zorlaştığı görülmüştür. Temel olarak öznitelik çıkarımına dayanan klasik makine öğrenme algoritmalarında bu özniteliklerin çıkarılması problem özelinde ve alan uzmanlığı ile olmaktadır. Öznitelikler arasından en önemli olanların seçilmesi kullanılacak makine öğrenme algoritmalarının eğitilmesinde kullanılır. Seçilen en önemli öznitelikler algoritmalarından elde edilen sonuçların geliştirilmesine ve iyileştirilmesine önemli ölçüde katkıda bulunur. Boyutun laneti [3] olarak adlandırılan fazla sayıda öznitelik üretilmesi sonucunda algoritmada ihtiyaç duyulan eğitim verisi sayısının beklenmedik şekilde artması problemlere neden olmaktadır. Algoritmaların eğitilmesi için verilecek olan veri setinin boyutunun küçük olması ve kullanılacak olan öznitelik sayısının fazla olması algoritmada aşırı uyuma sebep olmaktadır.

Böyle durumlarda algoritma veriyi ezberlemektedir. Aşırı uyum ve benzeri durumlarda sınıflandırma problemlerinde başarılı sonuçlar elde edilememektedir.

Bu tezde, veri seti olarak silindirik mayınlar ve bu mayınlara şekil olarak çok benzeyen silindirik kayalardan oluşan nesnelere ait sinyal ölçümlerinin olduğu, Gorman ve Sejnowski'ye [4] ait bir veri seti kullanılmıştır. Bu veri setinde bulunan sonar verisinin temsiline değiştirilmesi için Gramian Açısıl Alan, Markov Geçiş Alanı ve Tekrarlanma Grafiği olmak üzere üç farklı matematiksel dönüşüm metodu kullanılmıştır. Bu dönüşüm metotları sonar verisine ait farklı frekans bandından gelen bir boyutlu verileri, iki boyutlu resim formatına dönüştürmektedir. Dönüşüm metotlarının ilk aşamasında tek boyutlu verinin matris formunda temsili sağlanmaktadır. Matris formuna dönüştürülen veriler Tekil Değer Ayrışımı (TDA) yöntemi uygulanarak öz vektör ve öz değer matrislerinin elde edildiği üç farklı matrise ayrıştırılmıştır. TDA yöntemi ile veriye ait en dikkat çekici özellikler çıkarılarak elde edilen matris dönüşüm metotlarının ikinci aşaması olarak görüntüye dönüştürülmüştür. Aynı veriye ait her bir dönüşüm yöntemi ile oluşturulan görüntüler, görüntü birleştirme yöntemi ile tek bir görüntü haline getirilmiştir. Bu dönüşüm yöntemleri sonucunda verinin temsili değiştirilmiş ve görüntü veri seti oluşturulmuştur. Bu yeni oluşturulan veri seti ile klasik makine öğrenme algoritmaları yerine derin öğrenme algoritmaları arasında görüntü işleme konusunda en başarılı algoritmalarından biri olan Evrişimli Sinir Ağı algoritması kullanılmıştır. Bu tez kapsamında verinin temsili değiştirilmeden önce klasik makine öğrenmesi algoritmaları ile elde edilen sınıflandırma başarımları aracılığıyla değiştirildikten sonra kullanılan derin öğrenme algoritmalarından elde edilen başarımlar karşılaştırılmıştır. Ayrıca aynı veri seti ile gerçekleştirilmiş literatürde ki diğer çalışmalara ait kullanılan yöntemler ve başarımlar, önerilen yenilikçi yöntemin performansı ile karşılaştırılmıştır. Sınırlı sayıda veri barındıran bu veri seti ile önerilen yenilikçi yaklaşımda, bugüne kadar literatürde rapor edilen çalışmalar arasındaki en başarılı sonuçların elde edildiği gözlemlenmiştir.

Bu tezin ilerleyen kısımlarında; 2. bölümde bu çalışmada kullanılmış olan veri seti ile yapılmış diğer çalışmalara ait literatürde araştırılan çalışmalara yer verilmiştir. 3. bölümde üzerine çalışılan veri seti ile ilgili bilgilendirme yapılmıştır. 4. bölümde veri seti ile çalıştırılan klasik makine öğrenmesi yöntemlerinin ve önerilen yenilikçi yaklaşımda kullanılan yöntemlerin açıklamaları yapılmıştır. 5. bölümde bu tez kapsamında gerçekleştirilen deneysel çalışmalar ve önerilen yenilikçi yaklaşımların uygulamaları anlatılmış, 6. bölümde bu çalışmanın sonucunda elde edilen sonuçlar hakkında bilgiler verilmiş ve sonuçların performansları değerlendirilerek

karşılaştırma yapılmıştır. Son olarak 7. bölümde çalışmanın sonucunda elde edilen bilgiler, çalışmanın zorlukları ve yenilikçi yönleri ile gelecekteki çalışmalara yönelik değerlendirmeler anlatılmıştır.

2. LİTERATÜR TARAMASI

Bu bölümde tez çalışmasında ele alınan sonar sinyallerine ait veri seti kullanılarak yapılan diğer çalışmalar araştırılmıştır. İncelenen çalışmalarda kullanılan, geliştirilen algoritmalar ve bu algoritmalar sonucu elde edilen sonuçlar farklılık göstermektedir.

Bu tezde ve literatürde taranan çalışmalarda kullanılan veri setinin oluşturulduğu çalışmada [4], iki farklı su altı objesinden dönen sinyallere göre objenin silindirik mayın mı yoksa silindirik kaya mı olduğunun anlaşılması için görüş açısına bağlı ve görüş açısından bağımsız olacak şekilde 2 farklı çalışma gerçekleştirilmiştir. Her iki çalışmada da farklı gizli katmanlar, gizli katmanların ağı öğrenmesine olan etkisinin anlaşılması için kullanılmıştır. Çalışmalar 0, 2, 3, 6, 12 ve 24 sayıda gizli katman ile denenmiştir. Çalışmada oluşturulan bu ağ sınıflandırıcısının performansı, Öklid uzaklığı kullanılan K-En yakın komşu algoritması ile de kıyaslanmıştır. K-En yakın komşu sınıflandırma algoritmasından %82.7 doğruluk elde edilmiştir. Ayrıca algorithmadan elde edilen sonuçlar ile sonar sinyalleri konusunda uzman insanların sinyalleri incelemesinden elde edilen sonuçlar da karşılaştırılmıştır. İnsan performanslarından elde edilen sonuçlar %88 ile %97 doğruluk arasında değişmektedir. Geliştirilen sinir ağı ile yapılan denemeler sonucunda görüş açısına bağımlı çalışmalarda 12 gizli katman ile yapılan denemede test setinin performansı %90.4 olurken eğitim setinin performansı %99.8 olmuştur. Aynı çalışmada 24 gizli katman ile yapılan denemede test setinin performansı %89.2 iken eğitim setinin performansı %100 olmuştur. Görüş açısından bağımsız yapılan çalışmalarda en yüksek performans 12 gizli katman ile yapılan deneyde test setinde %84.7 olarak eğitim setinde ise %99.8 olarak bulunmuştur. Görüş açısından bağımsız yapılan çalışmada gizli katman sayısının 24'e çıkmasının sonucu daha iyiye taşımadığı gözlemlenmiştir. Elde edilen sonuçlarda, insanların inceleme performansından ve K-en yakın komşu algoritmasından elde edilen sonuçtan daha yüksek oranda doğruluk elde edildiği gözlenmiştir.

İncelenen bir diğer çalışmada [5], su altındaki sonar sinyallerinin tanımlanması ve sınıflandırılmasının su altı ortamının karmaşıklığından dolayı komplike bir yapıda olduğundan bahsedilmiştir. Çalışmada özellik çıkarmak için kullanılacak olan ön işleme adımının, girdi boyutunu artıracığından bahsedilmiştir. Temel bileşen analizi (PCA) ve nöral ayırma analizi (NDA) gibi özellik çıkarma tekniklerinin bu artan girdi boyutunu en yararlı ve ilgili bilgileri olarak daha düşük boyutlu bir özellik setine indirgediği anlatılmıştır. Ele alınan bu çalışmada su

altı hedeflerinin sınıflandırılması problemini çözmek amacıyla genel regresyon sinir ağı (GRNN) yöntemi kullanılmıştır. . Bu çalışmanın odaklandığı ana konu, sınıflandırıcı olarak genel regresyon sinir ağının, tek başına değil aynı zamanda özellik çıkarma tekniği olan temel bileşen analizi ile birlikte kullanılmasıyla performansın artması olmuştur. Veriler %50 eğitim, %50 test için kullanılmak üzere rastgele bölünmüştür. Çalışmanın doğruluğunun gösterilmesi için alıcı işletim karakteristiği (ROC) analizi kullanılmıştır. Çalışmanın sonucunda temel bileşen analizi yapılamadan %91,34 oranında doğruluk elde edilmiştir. Temel bileşen analizi ile birlikte aynı yöntem kullanıldığında ise %93,26 oranında doğruluk elde edilmiştir. Çalışma iki yöntemin bir arada kullanmasının performansı arttırdığını göstermiştir.

Su altı ortam şartlarından dolayı sonar görüntülerinin tespitinin ve sınıflandırılmasının zorluğundan bahsedilen bir diğer çalışmada ise [6], zamanla metal olan mayınların pasla kaplanacağından ötürü sadece görüntü işleme ile tanımlanamayacağı örneğinde olduğu gibi, görüntü işlemenin de yetersiz kalabileceği durumlar anlatılmıştır. Böyle durumlarda daha iyi sonuçlar alabilmek için görüntü işleme algoritmalarına yardımcı bir sınıflandırma algoritması kullanılması gerektiğinden bahsedilmiştir. Veri setinin %80 eğitim, %20 test olarak ayrıldığı çalışmada, gradyan artırma, karar ağacı ve k-en yakın komşu algoritmaları ile çalışılarak elde edilen sonuçlar karşılaştırılmıştır. Çalışmalarını yaparken verileri tüm özellik seti ve en az yanlış negatif orana sahip özelliklerin seçildiği seçilmiş özellik seti (FNR) olarak iki ayrı grupta incelemişlerdir. Tüm özellik setini alarak yaptıkları çalışmada gradyan artırma algoritmasından %90, K-En yakın komşu algoritmasından %80, karar ağacı algoritmasından ise %78 başarı oranları elde edilmiştir. Tüm özellik setini almayıp kendi hazırladıkları seçili özellik setini kullanarak yaptıkları çalışmada ise gradyan artırma algoritması ile %85.7, K-En yakın komşu algoritması ile %85, karar ağacı algoritması ile %64 başarı oranları elde edilmiştir. Çalışmada elde edilen sonuçlara göre en iyi sonucu veren algoritma tüm özellik seti ile çalıştırılan gradyan artırımı algoritması olmuştur.

Özellikle sonar sinyallerinin tespitinin ve sınıflandırılmasının sahadaki en zorlu konulardan biri olduğu vurgulandığı çalışmada ise [7], veri setinde gerçekleşen filtreleme ve ön işleme adımları klasik yöntemlerdeki gibi model öğrenmeye başlamadan önce değil, tüm işlemler ile eş zamanlı yapılmıştır. Artan veri seti boyutunun ileride performans konusunda yaratacağı problemlere de çözüm olacağı düşünülerek iDSM-CA adı altında yeni bir yöntem sunulmuştur. Çalışmalarında önerdikleri iDSM-CA yöntemi ile gürültü algılama, filtreleme ile hatalı verilerin kaldırılması, ön işleme gibi model eğitimi öncesi yapılacak tüm adımlar öğrenme sürecine yerleştirilmiştir.

Bu yaklaşıma göre ön işleme ve eğitimi, veri akışı ile başlayan testin takip ettiği söylenmiştir. iDSM-CA yöntemi ile toplamda 6 adet sınıflandırma algoritması ile çalışmalar yapılmıştır. DT with iDCM-CA ve LWL with iDCM-CA yöntemleri %96.25 ile bu 6 adet yöntem arasından en yüksek doğruluğu veren yöntemler olmuştur.

Aynı veri seti ile gerçekleştirilen ele alınan diğer çalışmada [8] sınıflandırma için genetik algoritmanın ve bu algoritmadan esinlenen 9 adet örnek tabanlı genetik algoritma modelinin (IbGA) içlerinde sonar veri setinin de bulunduğu toplam 19 adet veri seti üzerinde çalıştırılmasından bahsedilmiştir. Örnek tabanlı genetik algoritma modelleri çalışılan veri setleri üzerinde genelleme yeteneği ve eğitim verimliliği konusunda daha iyi bir performans elde edebilmek için çeşitli şekillerde kullanılmış ardından elde edilen başarımlar karşılaştırılmıştır. Elde edilen sonuçlarda yer alan her bir kombinasyonun, modelin genelleme yeteneğini ve eğitim süresinin verimliliğini etkilediği kanıtlanmıştır. Çalışmalar sonucunda sonar veri seti için en yüksek başarı oranının %53.43 ile TS2 isimli modelden elde edildiği gözlemlenmiştir.

Aynı veri seti ile yapılmış bir diğer çalışmada [9], C4.5 karar ağacı ile sonar hedeflerinin tespiti ve sınıflandırılmasında bilgi kazanımı değerlendirilmesinin uygulaması anlatılmıştır. C4.5 karar ağacının sınıflandırma ile ilgili özelliklere odaklanma ve ilgisiz olanları göz ardı edebilme yeteneği ile bilgi kazanımı öznitelik değerlendirme yeteneği birleştirilerek karar ağacı performansı artırılmıştır. Çalışma yapılırken on kat çapraz doğrulama kullanılmıştır. Çalışma sonucunda, bilgi kazanımı öznitelik değerlendirilmesi ile birlikte çalışan C4.5 karar ağacı algoritmasından elde edilen doğruluk, tek başına çalıştırılan karar ağacı algoritmasından elde edilen sonuçtan %10 artarak, yaklaşık %81 olarak bulunduğu gözlemlenmiştir.

Sınıflandırma yapılırken, bulunması hedeflenen karar sınırının elde edilmesinin çok zor olduğundan bahseden aynı veri seti ile ele alınan çalışmada [10], bu sorunun çözülmesi için Artımlı Maksimum Gauss Karışımı Bölümü algoritması (IMGMP) önerilmiştir. Bu algoritma uygun karar sınırının hesaplanması için böl ve yönet stratejisini kullandığından bahsedilmiştir. Çalışmalarında verilerin kümelenmesi için K-ortalamlar algoritması kullanılmıştır. K-ortalamlar algoritması ile Maksimum Gauss Karışım modelinin birlikte kullanıldığı çalışma sonucunda %82.79 oranında doğruluk elde edilmiştir.

Bu çalışma [11], daha yüksek bir doğruluk derecesi ile indirgenmiş seyrek formlarını kullanarak sinyalleri sınıflandırmak için bir yöntem belirlemeyi amaçlamaktadır. Sonar, radar veya sismik

sinyaller gibi birçok sinyal ya seyrek ya da uygun temelde ifade edildiğinde seyrek ya da sıkıştırılabilir gösterimlere sahip olmaları anlamında seyrek hale getirilebilir. Az sayıda seyrek katsayıların onları sinüzoidallerin, dalgacıkların veya diğer bazların doğrusal toplamaları olarak ifade ettiği uygun bir dönüşüm alanına sahiptirler. Gerçek değerli yapay sinir ağları (YSA) uzun süredir sonar sinyallerinin sınıflandırılmasında sıklıkla kullanılmasına rağmen, bu çalışmada sonar sinyallerinin bu karmaşık indirgenmiş seyrek formları için karmaşık değerli dalgacık sinir ağı (CVWANN) kullanılmaktadır. Sınıflandırmadan önce girdi sayısı 1/3 boyutuna indirilmiştir. İndirgenmiş formdan elde edilen karmaşık değerli seyrek katsayılar (CVSC'ler) CVWANN tarafından sınıflandırılmıştır. Önerilen yöntemin performansı sunulur ve diğer sınıflandırma yöntemleriyle karşılaştırılır. Çalışmada önerilen yöntem, CVSCs -CVWANN, on kat çapraz doğrulama veri seçiminde% 94,23 ve% 50–50 eğitim-test veri seçiminde% 95,19 oranında başarılıdır.

Aynı veri seti ile yapılan diğer çalışmada [12], verilerin ön işlemlerinden sonra, sınıflandırma başarılarını ölçmek için destek vektör makineleri algoritması, C4.5 karar ağacı, naive bayes algoritması gibi toplamda 10 farklı makine öğrenme yöntemi denenmiştir. Özellik çıkarımı için Gini indeksinin kullanıldığı bu çalışmada bu indekse göre 50 özellik seçilmiştir. Yapılan çalışmada %83.17 ile en yüksek doğruluk oranının elde edildiği yöntem rassal orman yöntemi olmuştur. Bu yöntemin performansını arttırmak için özellik seçim tekniği kullanılarak model optimize edilmiş ve sonuç %91.15'e yükseltilmiştir.

Çekirdek işlevleriyle destek vektör makinesini kullanarak özellik seçimi için Kernel Parameter Descent Support Vector Machine (KPD-SVM) olarak adlandırılan yeni bir algoritmanın sunulduğu bu çalışmada [13], destek vektör makinesi modelinin eğitiminde hedef fonksiyonlarını optimize etmek için çekirdek fonksiyonlarının parametreleri değişken olarak alınmış. Yapılan bu çalışma parametreleri optimize ederek daha az önemli özellikleri ortadan kaldırarak sınıflandırma performansını iyileştirmeyi amaçlamaktadır. Yöntemlerinin verimliliğini ve performansını ölçmek için Fisher kriter puanı ve özyinelemeli özellik eliminasyon destek vektör makineleri algoritmaları ile karşılaştırma yapmışlardır. %87.30 doğruluk oranı ile karşılaştırıldığı algoritmalarından daha iyi sonuçlar alındığı raporlanmıştır.

Doğası gereği son derece gürültülü olan sonar verisi ile ikili sınıflandırma problemi için çeşitli makine öğrenme algoritmalarının kullanıldığı çalışma incelenmiştir [14]. İncelenen bu çalışmada içlerinde XGBoost, Kübik evrişimli sinir ağları, lojistik regresyon gibi algoritmaların

bulunduğu toplamda 29 adet makine öğrenmesi algoritması ile yapılan çalışmada sonuçlar, veri setinin de alındığı Gorman ve Sejnowski'nin 1988 de yayınladığı makaledeki sonuçlar ile karşılaştırmıştır. Çalışılan algoritmalarındaki doğruluk oranları %53.4 ve %88.1 arasında değişmektedir. En yüksek doğruluk oranının elde edildiği algoritma ise XGBoost algoritmasıdır.

Sinir ağlarına ait ikili sınıflandırma modelinin kullanılması ile yapılan bu çalışmada [15] veriler karıştırılıp %80'i eğitim, %20'si test olarak ayrılmıştır. Ayrıca sinir ağındaki gizli nöronlarında sabitlendiği bu çalışmada ağ azaltma tekniği ile gizli katmanlardaki benzer nöronlarda kaldırmışlardır. Kaldırılacak olan bu benzer nöronlara karar vermek için, her bir nöron için bir vektör oluşturulmuş ve her bir vektör ile nöron arasındaki açı hesaplanmıştır. Aradaki açı 30 dereceden az ise iki gizli nöronun benzer olduğu kanısına varılmış ve bu nöronlar kaldırılmıştır. Çalışmalarında gerçekleştirdikleri iki farklı sinir ağı versiyonuna ait iki farklı doğruluk oranı elde etmişlerdir. Birinci versiyonda doğruluk %86, ikinci versiyonda ise %75.79 olarak hesaplanmıştır. Gelecekte aynı olan gizli nöronların belirlenmesi için daha fazla araştırma yapılmasına ve öğrenme aşaması için daha karmaşık ve detaylı bir algoritma kullanılmasına ve ön işleme aşamasını iyileştirmek için daha fazla araştırma yapılmasına karar verildiğini belirterek çalışmalarını tamamlamışlardır.

K- En yakın komşu algoritmasının kullanıldığı başka bir çalışmada [16] ise kullanılacak olan veri setinin büyüklüğü arttıkça ortaya çıkacak olan hesaplama maliyeti artması gibi sorunlardan dolayı MIME- K-NN adı verilen yeni bir algoritma önerilmiştir. K-En yakın komşu algoritması eğitim verileri ile test verileri arasındaki mesafenin hesaplanması ile işlem yaptığı için veri setinin büyüdüğünde hesap karmaşıklığı artacağından dolayı sınıf içi mesafeyi minimum tutarken, sınıflar arası mesafeyi maksimum düzeye çıkarmayı hedeflemişlerdir. Çalışmalar sonucunda klasik K-En yakın komşu algoritmasından %74.50 doğruluk oranı elde edilirken, ortaya çıkarttıkları MIME-K-NN isimli algorithmadan elde edilen sonuç %82.20 olmuştur.

Literatürde incelenen tüm çalışmalara ait sonuçlar Çizelge 2.1'de verilmiştir.

Çizelge 2.1. Literatürdeki yöntemlere ait karşılaştırmalı sonuç tablosu

Makale	Kullanılan Yöntem	Doğruluk (%)
[4]	12 Gizli Katmanlı-Görüş açısına bağlı	90,40
	12 Gizli Katmanlı-Görüş açısından bağımsız	84,7
[5]	GRNN	91,34
	GRNN - PCA	93,26
[6]	Gradyan Artırma	90,00
	K-NN	80,00
	DTA	78,00
[7]	NBup with iDCM-CA	82,50
	SVM with iDCM-CA	60,00
	NN with iDCM-CA	88,75
	DT with iDCM-CA	96,25
	IBK with iDCM-CA	85,00
	LWL with iDCM-CA	96,25
[8]	RS1	49,50
	RS2	51,95
	RSU	51,40
	TS1	51,93
	TS2	53,43
	TSU	49,98
	RW1	51,93
	RW2	52,88
	RWU	51,38
[9]	C4.5 with BK	81,00
[10]	IMGMP	82,79
[11]	CVSCs -CVWANN	95,19
[12]	Optimized Rassel Orman	91,15
[13]	KPD-SVM	87,30
[14]	XGBoost	88,10
[15]	24 Gizli katman – İkili sınıflandırma	86,00
[16]	MIME-KNN	82,20



Çizelge 2.1’de bu tez çalışmasında kullanılan veri seti ile makine öğrenmesi, bilgi kazanımı, özellik çıkarımı gibi farklı yöntemler ile literatürde gerçekleştirilmiş çalışmalara ait sonuçlar verilmiştir. Bu sonuçlar karşılaştırılırken tüm çalışmalarda ortak performans metriği doğruluk olduğu için doğruluk değerleri üzerinden karşılaştırma yapılmıştır. Sonuçlar karşılaştırıldığında %96,25 ile en yüksek sonucun veri ön işleme ve eğitiminin yapılması için yenilikçi bir yaklaşım getiren çalışmadan [7] alındığı gözlemlenmektedir.


Görüntü işleme problemlerinde derin öğrenme algoritmaları özellikle evrişimli sinir ağı mimarisi kullanımı oldukça yaygındır. Öznitelik çıkarım işlemlerinin veriden doğrudan yapıldığı bu algoritmalar ile yapılmış çalışmalar oldukça fazladır. Verinin temsilinin değiştirildiği ve derin sinir ağlarının kullanıldığı çalışmada [17] zararlı yazılım dosyaları görselleştirilmiş ve sınıflandırılmıştır. Çalışmalarında kullandıkları 2015 yılına ait Microsoft zararlı yazılım veri seti bu tez çalışması kapsamında da kullanılan tekrarlanma grafiği matematiksel dönüşümü ile görüntüye dönüştürülmüştür. Elde edilen görüntüye dönüştürülmüş veri seti evrişimli sinir ağı mimarisi ile sınıflandırılmıştır. Elde edilen sonuçlarda önerilen yöntemin daha yüksek performans gösterdiği gözlemlenmiştir. Yine benzer bir yöntemin uygulandığı bir diğer çalışmada [18] epilepsi tanısında EEG sinyallerinden alınan verilerin yine bu çalışmada kullanılan Gramian açısıl alan dönüşümü ile görüntüye çevrilmesinden sonra derin sinir ağı ile sınıflandırılmasından bahsedilmektedir. Çalışmada AlexNet, VGG16 ve VGG19 gibi evrişimli sinir ağı modelleri kullanılmıştır. Çalışma sonucunda önerilen yöntemin epilepsi tespiti için alternatif bir yaklaşım olarak kullanılabileceğinden ve bu yöntemin kesinlik, geri getirme ve F_1 skoru açısından daha iyi performansa sahip olduğundan bahsedilmiştir. Yapılan literatür taraması sonucunda, 60 farklı frekans bandından toplanan sonar sinyallerinin bulunduğu veri seti ile yapılmış veri setinin temsilinin değiştirildiği ve derin öğrenme algoritmaları ile kullanıldığı bir çalışmaya rastlanmadığı gözlemlenmiştir.

3. VERİ SETİ

Bu tez çalışmasında kullanılan veri seti, Allied-Signal Havacılık ve Uzay Teknoloji Merkezi'nde R. Paul Gorman ile işbirliği içinde geliştirilmiştir. 1987 yılında silindirik mayınlar ve bu mayınlara şekil ve yapı olarak çok benzeyen silindirik kayalardan yansıyan sinyaller ile oluşturulmuştur. Elde edilen bu veriler ilk olarak Gorman ve Sejnowski [4] tarafından sinir ağı yöntemi ile sınıflandırılma çalışmasında kullanılmıştır. Bu çalışmada amaç silindirik bir mayından seken sonar sinyaller ile silindirik bir kayadan seken sonar sinyalleri birbirinden ayırmaktır.

Veri seti elde edilirken kumlu bir okyanus tabanına her biri yaklaşık 1.5 metre uzunluğunda silindirik mayınlar ve silindirik kayalar yerleştirilmiştir. Her birine yaklaşık 10 metreden sinyaller gönderilmiştir. Silindirik kayalar için 180 derece ve silindirik mayınlar için 90 dereceye kadar olma şartı ile farklı açılardan gönderilmiş sinyallere geri dönüş olarak 1200 adet sinyal toplanmıştır. Bu sinyallerden her bir görüş açısına gelenlerin arasından rastgele seçilen ortalama 5 dönüş sinyali alınarak 208 adet veri elde edilmiştir. Her bir nesneye ait veri 0.0 ile 1.0 aralığında 60 sayılı bir seriden oluşmaktadır. Bu veri setindeki her sayı belirli bir zaman dilimi boyunca birleştirilmiş, özel bir frekans bandındaki enerjiyi temsil etmektedir. Elde edilen verilerin 97 tanesi silindirik kayaları, 111 tanesi silindirik mayınları temsil etmektedir. Veri setinde bulunan verilere ait her sayı tam açı değerini yansıtmasa da artan bir açı sırasına göre sıralanmıştır. Veriye ait sınıflandırma yapılırken veri kaya ise R, mayın ise M olarak etiketlemesi yapılmıştır. Şekil 3.1'de bir adet silindirik mayın ve bir adet silindirik kayaya ait dönüş değerlerinin olduğu grafik mevcuttur. Bu grafik mayın ve kayadan dönen frekans bandındaki verilerin farklılığını göstermektedir. Şekil 3.2'de tüm kaya hedefleri için ölçüm yapılan frekans bandında karşılık gelen sinyal dönüş değerlerinin grafiksel gösterimi yapılırken Şekil 3.3'de tüm mayın hedefleri için aynı grafiksel gösterim mevcuttur.





Şekil 3.3. Kaya hedefleri için ölçüm yapılan frekans bandına karşılık gelen sinyal dönüş değerleri

4. KULLANILAN YÖNTEMLER VE METODOLOJİ


Bu bölümde tez çalışmasında kullanılan yöntemler ve bu yöntemlere ait açıklamalar verilmiştir. İlk olarak verinin matematiksel dönüşümü öncesi uygulanan klasik makine öğrenme algoritmaları ve bu algoritmalara ait açıklamalara yer verilmiştir.

Tez çalışmasının ikinci kısmında verinin temsilinin değiştirilmesi ve görüntülerden oluşan yeni veri setinin elde edilmesi için kullanılan sensör verisi görüntü dönüşümü yaklaşımı, bu dönüşüm için kullanılan yöntemler olan Gramian Açısıl Alan Dönüşümü, Markov Geçiş Alanı Dönüşümü, Tekrarlanma Grafiği Dönüşümü açıklamaları verilmiştir. Verinin matematiksel dönüşüm yöntemleri ile temsilinin değiştirilmesi sürecinde veri matris formunu aldıktan sonra bu form ile kullanılan Tekil Değer Ayrıştırması yöntemi ve bu yöntem tamamlandıktan sonra elde edilen görüntü verilerinin 3 kanallı tek bir görüntüde birleştirilmesi açıklanmıştır.

Bu çalışmada önerilen yenilikçi yöntem bir boyutlu sensör verisi türündeki frekans bandından alınan verilerin iki boyutlu resim formatına dönüştürülmesini temel almaktadır. Dönüştürülen resimler kırmızı-mavi-yeşil ya da siyah-beyaz olacak şekilde ikili olabilmektedir. Yapılan dönüşümlerde her frekans bandına ait verilerin uzamsal ve zamansal değişimleri farklı şekillerde ele alınarak iki boyutlu görüntüler elde edilmiştir. Verinin sayısal olarak temsilinin değiştirilmesi ile veri tek boyutlu iken kullanılamayan ya da elde edilemeyen özniteliklerin ortaya çıkması sağlanarak yapılacak olan sınıflandırmada başarı oranının artırılması amaçlanmıştır. Dönüşüm yöntemleri ile görüntü temsiline dönüştürülen verilerde klasik makine öğrenme algoritmalarının yanı sıra görüntü işleme teknikleri kullanılarak ikili sınıflandırma problemi çözülmesi amaçlanmıştır.


İlk olarak sensör verisi formunda frekans bantlarından alınan veriler, birbirinden farklı, belirli özellikler taşıyan Gramian Açısıl Alan, Markov Geçiş Alanı ve Tekrarlanma Grafiği adı verilen matematiksel dönüşüm metotları kullanılarak görüntü formatlarına dönüştürülmüştür. Bu dönüşümler sonucu elde edilen görüntüler ile her bir dönüşüm metoduna ait yeni bir görüntü veri seti elde edilmiştir. Bu görüntü veri setleri mayın ve kaya olarak ayrılmıştır. Oluşturulan yeni veri setinin ilk olarak %67'si eğitim için, %33'ü ise test için kullanılmak üzere ayrılmıştır. Veri seti hazırlığı tamamlandıktan sonra görüntü işleme konusunda oldukça başarılı olan

Evrişimli Sinir Ağı mimarisi kullanılarak 10 kat çapraz doğrulama ile eğitilmiş ve test edilmiştir. Önerilen bu yöntem ve dönüşümlere ait akış diyagramı Şekil 4.1’de verilmiştir.



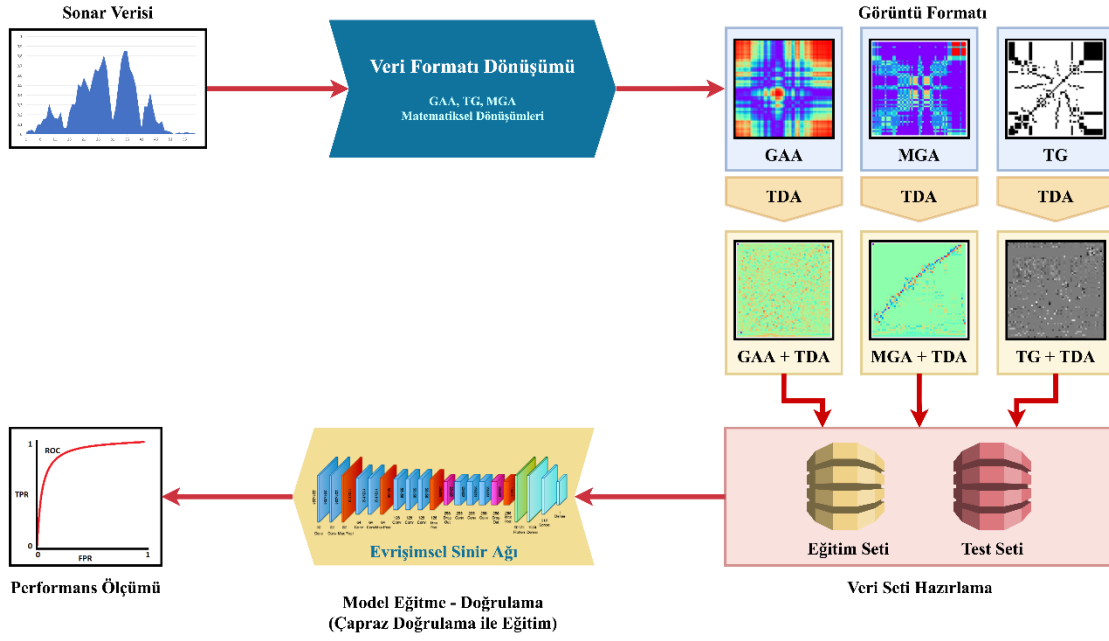
Şekil 4.1. Önerilen birinci yöntemle ait akış diyagramı

İkinci olarak görüntü formatında elde edilen her bir dönüşüm yöntemine ait 3 veri setindeki veriler görüntü füzyon yöntemi ile bir resmin üç farklı kanalını oluşturacak şekilde birleştirilmiş ve bu üç ayrı veri seti özellik artırımı için tek bir veri seti haline getirilmiştir. Bu yeni birleşmiş veri setinin %80’i eğitim, %20’i test için kullanılmak üzere ayrılmıştır. Evrişimli sinir ağı mimarisi ve 10 kat çapraz doğrulama ile veriler eğitilmiş ve test edilmiştir. Görüntü birleşiminin eklendiği önerilen yöntemle ait akış diyagramı Şekil 4.2’de verilmiştir.



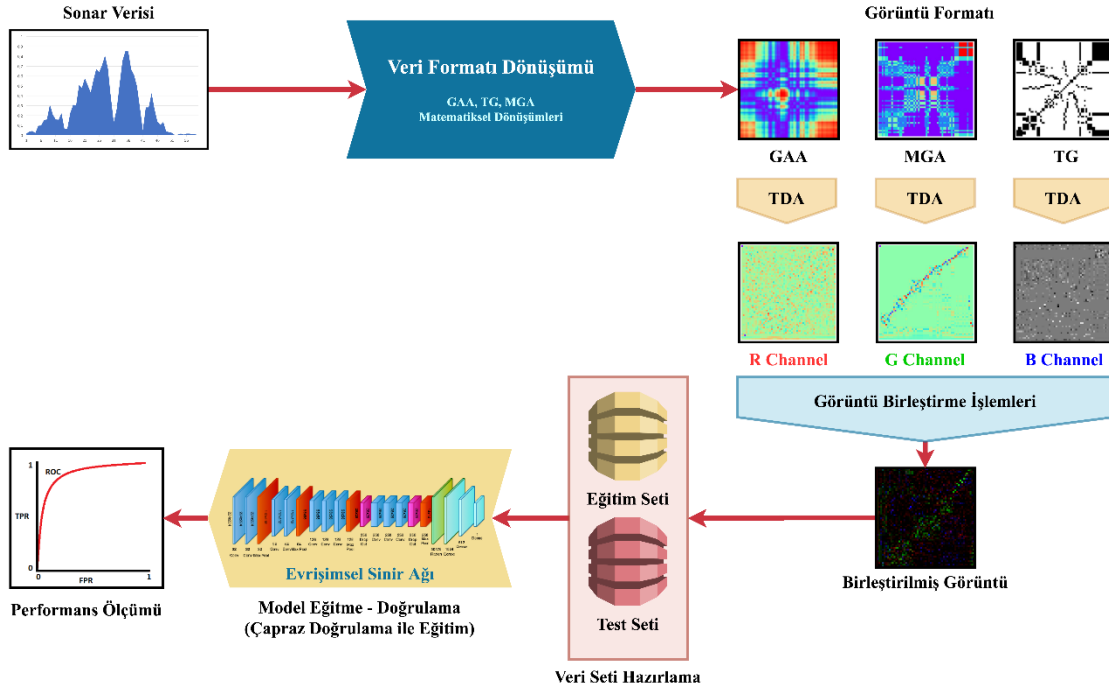
Şekil 4.2. Önerilen ikinci yönteme ait akış diyagramı

Önerilen bu yenilikçi yönteme ek olarak öznelilik çıkarımını ve buna bağlı olarak sınıflandırma başarısını arttırmak için matematiksel dönüşüm yöntemleri uygulanırken verinin temsili değiştirilip matris formunu aldığımda Tekil Değer Ayrışımı yöntemi ile tek boyutlu veriden elde edilen matris öz vektör ve öz değer matrislerine ayrılmıştır. Bu yöntem ile verinin en dikkat çekici öznelilikleri oraya çıkarıldıktan sonra dönüşüm yöntemi tamamlanarak veriler görüntüye çevrilmiştir. Her bir dönüşüm yöntemi için ayrı ayrı yeni görüntü veri setleri oluşturulduktan sonra veri setinin %80'i eğitim kalan %20'si test için kullanılmak üzere ayrıştırılmıştır. Elde edilen veriler evrişimli sinir ağı mimarisi ve 5 kat çapraz doğrulama ile eğitilmiş ve test edilmiştir. Tekil değer ayrışımının eklendiği bu yönteme ait akış diyagramı ise Şekil 4.3'de verilmiştir.



Şekil 4.3. Önerilen üçüncü yönteme ait akış diyagramı

Son olarak tekil değer ayrışımı yöntemi ile en önemli öznelilikleri ortaya çıkan öz değer matrisler yukarıda bahsi geçen 3 farklı dönüşüm yöntemi ile görüntüye dönüştürüldükten sonra 3 farklı görüntü veri seti elde edilmiştir. Elde edilen bu 3 farklı görüntü veri seti yine yukarıda bahsi geçen şekilde görüntü füzyon tekniği ile farklı dönüşüm yöntemlerinden elde edilen veriler tek bir görüntünün 3 ayrı kanalına verilerek birleştirilmiştir. Oluşturulan bu yeni veri setinin %75'i eğitim kalan %25'lik kısmı test için kullanılmak üzere ayrılmıştır. Evrişimli sinir ağı mimarisi ve 5 kat çapraz doğrulama ile eğitilmiş ve test edilmiştir. Son olarak bugüne kadar elde edilen tecrübeler ile önerilen yenilikçi yöntemin geldiği son noktada gerçekleşen akış diyagramı ise Şekil 4.4'de verilmiştir.



Şekil 4.4. Önerilen dördüncü yönteme ait akış diyagramı


4.1. Kullanılan Makine Öğrenmesi Yöntemleri

Tez çalışmasının bu bölümünde çalışmada kullanılan veri setinin herhangi bir dönüşüme uğratılmadan önceki hali ile birlikte çalıştırılmış klasik makine öğrenmesi algoritmalarının açıklamaları mevcuttur. Verinin sayısal temsili değiştirilmeden önce veri üzerinde destek vektör makineleri algoritması, doğrusal ayrımcılık analizi algoritması, lojistik regresyon algoritması, GaussianNB algoritması, karar ağacı algoritması, rassal orman algoritması ve k-en yakın komşu algoritması ile çalışmalar yapılmıştır.

4.1.1. Destek vektör makineleri algoritması

Vladimir Vapnik ve Alexey Chervonenkis tarafından 1963 yılında oluşturulmaya başlanmış, 1995 yılında ise yine Vladimir Vapnik, Bernhard Boser ve Isabelle Guyon tarafından geliştirilmiş olan destek vektör makineleri (DVM) istatistiksel öğrenme teorisine dayalı bir denetimli öğrenme algoritmasıdır [19]. Sınıflandırma problemlerinde kullanılan denetimli öğrenme algoritma kategorisinde bulunan destek vektör makineleri algoritması, düzlem üzerinde bulunan noktaları birbirinden ayırmak için hiper düzlemler belirleyen vektör uzayı tabanlı bir algoritmadır. Destek vektör makineleri algoritması çalışılacak veri setinin doğrusal olup olmamasına göre ikiye ayrılmaktadır. Doğrusal DVM algoritması verilerin birbirinden ayrılması için karar doğrusunu

çizmektedir. Çizilecek olan karar doğrusu yeni eklenebilecek diğer veriler ile kullanılabilir olması için ayrılacak olan sınıfların, sınıf çizgilerine destek vektörleri adı verilen en yakın uzaklıkta olacak noktalar şekilde belirlenir. Destek vektörleri, ait oldukları sınıfların sınırlarını belirlemektedir. Sınıflandırmanın en doğru şekilde yapılabilmesi için sınıflara en yakın ve birbirine paralel şekilde sınır çizgileri çizilerek sınır düzlemi oluşturulur. Bu sınır düzleminin tam ortasından geçen ve iki tarafa da eşit uzaklıkta bulunan hiper düzlem çizilir. Doğrusal olmayan DVM algoritmasında doğrusal bir hiper düzlem çizilemeyeceğinden dolayı “kernel trick” adı verilen çekirdek fonksiyonlarını kullanır. Çekirdek fonksiyonları doğrusal olarak ayrılmayan veri setlerinde, girdi vektörünün boyutunu artırarak doğrusal olarak ayrılabilir hale gelmesini sağlamaktadır. Farklı çekirdek fonksiyonları ile çok yönlü olabilen DVM algoritması bu avantajları sayesinde doğrusal olarak ayrılmayan verilerde karar doğrularını oluşturabilmek için çekirdek fonksiyonlarını kullanabilirler. DVM algoritması veri seti boyutu yüksek olduğunda hesaplama maliyetinin dengelenmesi için de çekirdek hilesi yönteminden faydalanmaktadır. Hem doğrusal hem de doğrusal olmayan verilere uyarlanabilmesi, karmaşık karar sınırlarını çizebilme yeteneği ve fazla sayıda bağımsız değişkenle çalışabilme yeteneğinden dolayı daha yüksek doğrulukta sonuçlar elde edilmektedir [20] [21].




Şekil 4.5. Destek vektör makineleri algoritması (DVM)

4.1.2. Doğrusal ayırmıcılık analizi algoritması

Doğrusal ayırmıcılık analizi, hesaplama verimliliğini artırmak ve düzensiz modellerde boyutun laneti [3] nedeni ile aşırı uyum derecesini azaltmak amacı ile özellik çıkarımı tekniği olarak kullanılabilir. Bu algorithmadaki asıl amaç, sınıflandırmayı optimize eden özellik alt uzayını bulmaktır. Hesaplama verimliliğini artırmak ve düzensiz verilerde aşırı uyumun önüne geçmek için kullanılmaktadır [20]. Gözetimsiz bir algoritma olan DAA algoritması kovaryans matrisini kullanarak veri setini ayrıştırmakta ve sınıflar arası ve sınıf için dağılım matrislerini oluşturmaktadır. Oluşturulan bu matrisler küçük boyutlu özellik uzaylarına dönüştürülmektedir. Fisher'in skor fonksiyonuna göre çalışıp skoru maksimize edecek olan doğrusal katsayıları tahmin etmektedir. İki sınıfı birbirinden ayırmaya yardımcı olan özelliklerin bulunacağı Fisher'in skor fonksiyonunun hesaplanmasına ait matematiksel gösterim "Eş. 4.1'de" verilmiştir [22].

$$F(x_i) = \frac{|\mu_i^+ - \mu_i^-|}{\sigma_i^+ - \sigma_i^-} \quad (4.1)$$

Yukarıdaki eşitlikte verilen μ_i^- ve μ_i^+ değerleri iki sınıflı bir problem için farklı sınıfların aritmetik ortalamalarını verirken σ_i^+ ve σ_i^- değerleri farklı sınıflara ait standart sapma değerlerini göstermektedir. Fisher'in skor fonksiyonu veri sınıfları aralarındaki farkları, veriyi açıklayacak olan değişkenlerin doğrusal kombinasyonlarını bularak modellemektedir. DAA algoritması sınıflar arasındaki farkı maksimize ederek boyut azalma amacı ile sınıflandırma işlemleri öncesinde özellik çıkarmak için ön işleme olarak da kullanılabilir [23][24].




Şekil 4.6. Destek vektör makineleri algoritması (DVM)

4.1.3. Lojistik regresyon algoritması

Denetimli makine öğrenme algoritmalarından biri olan lojistik regresyon algoritması doğrusal ve ikili sınıflandırma problemleri için basit ancak güçlü bir algoritmadır. LR algoritması bir veya birden fazla bağımsız değişken barındıran veri setlerinin analizi için kullanılır. Doğrusal regresyon modelinde bağımlı değişkenlerin sürekli olması durumunda kullanılmaktadır. Bu yöntemin kullanılmasının amacı parametrelerin arasından veri setinin olma olasılığını maksimize eden en iyi parametrelerin seçilmesini sağlamaktır. LR algoritmasında eldeki veriye en uygun lojistik fonksiyonun regresyon katsayıları optimize edilerek hesaplanmaktadır. Kategorik veriler ile çalıştırıldığında daha iyi sonuçlar vermektedir. Lojistik regresyon algoritması bir değişkenin olma olasılığı ile veri setindeki öznitelikler arasındaki ilişkiyi kurmaktadır. Tahmin edilecek sınıf ile değil, aynı zamanda sınıftaki değişkenin olma olasılığının logaritmik oranının tahmin edilmesi ile ilgilenmektedir. Logaritmik oranın tahmin edilmesi için logit fonksiyonu kullanılmaktadır [25]. Bu fonksiyonun matematiksel gösterimi “Eş. 4.2’de” verilmiştir.

$$\text{logit } p = \ln \frac{p}{1-p} \text{ for } 0 < p < 1 \quad (4.2)$$

LR algoritmasına bağımsız değişkenler ekleme, algoritmanın istatistiksel geçerliliğini artırır. LR algoritması ile oluşturulacak modele fazla sayıda değişken eklenmesi aşırı uyumun meydana gelmesine ve modelin performansının düşmesine sebep olmaktadır [26].




Şekil 4.7. Lojistik regresyon algoritması (LR)

4.1.4. GaussianNB algoritması

Denetimli öğrenme algoritmalarından birisi olan GaussianNB algoritması, Naive Bayes algoritmasının bir türüdür. Veri setinde bulunan her bir eleman için bütün durumların olasılıkları hesaplanır ve elde edilen sonuçların yüksekliğine göre sınıflandırma yapılır. Dengesiz ve düşük boyutlu veriler ile başarılı bir şekilde çalışabilmektedir. Test için ayrılan veri setindeki elemanlardan birinde bulunan bir değere, eğitim veri setindeki elemanlarda rastlanmaz ise değeri sıfır olarak verir ve bu değer ile ilgili tahmin yapamaz. Bu durum sıfır frekans olarak da bilinmektedir. Naive Bayes algoritmasından farklı olarak veriler kategorik olmak yerine sürekli değişen bir durumda olduklarında GNB algoritması kullanılmaktadır [20]. Var olan özellikler sürekli değer ise bu değerlerin normal dağılımdan örneklenen bir gauss dağılımı olduğu kabul edilmektedir. GNB algoritmasında her özellik birbirinden bağımsız kabul edilmektedir. Ancak modeli oluşturacak verilerde birbirine çok benzeyen kategoriler var ise bu kategorilerin birden fazla sayılıp olması gerekenden fazla önemli sayılmaması adına bunlardan bir tanesi ön işleme kısmında çıkarılmalıdır. GNB algoritması model performansının artması için ön işleme ve özellik seçme aşamalarında iyileştirilebilecek çok fazla parametre imkânı sunmaktadır. GNB algoritmasının matematiksel gösterimi “Eş. 4.3.’te” verilmiştir.

$$P(x_i | y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_i - \mu_y)^2}{2\sigma_y^2}\right) \quad (4.3)$$

Yukarıda verilen eşitlikte μ değeri ortalamayı, σ^2 değeri ise varyansı göstermektedir [27] [28].



Şekil 4.8. Gaussian NB algoritması.

Yukarıda verilen şekilde verilen her bir veri noktasında, o nokta ile her sınıfın ortalaması arasındaki z skor mesafesi hesaplanmaktadır.


4.1.5. Karar ağacı algoritması

Eğitim veri setindeki özelliklere dayanarak, bir dizi soru sorarak karar veren ve verilerimizi bu kararlara göre birbirinden ayırabilen denetimli öğrenme algoritmasıdır. Hem sayısal hem de kategorik verilerin işlenmesinde kullanılmaktadır. Yorumlanabilirliğin önemsendiği çalışmalarda daha çok tercih edilmektedir. Karar ağacı algoritması, ağacı oluşturma ve ağacı budama olarak iki aşama ile gerçekleştirilmektedir. Karar ağaçları, karar düğümleri ve yaprak düğümlerinden oluşmaktadır. Karar ağacında her bir öznitelik bir düğüm tarafından temsil edilmektedir. Bu algorithmada yaprak en son yapı, kök en üst yapı olarak adlandırılmaktadır. Yinelemeli bir süreçte yapraklar en küçük parçalara ayrılana kadar bölme işlemi devam ettirilerek ağaçtaki düğüm yapısı büyütülebilir. Bu işlem özyineli olarak tekrarlanır ve tekrarlama işlemi sınıflama üzerinde etkisi kalmayana kadar devam eder. Veri sayısına ve yapısına bağlı olarak fazla düğümlü derin ağaçlarda aşırı uyum gözlemlenebilmektedir. Düğüm sayısı arttıkça modelin karmaşıklığı da artmaktadır. Bu nedenle genellikle ağacın maksimum derinliği için bir sınır belirlenerek ağacın budanması sağlanmaktadır [20]. İki çeşit budama yöntemi vardır bunlar erken budama ve geç budama olarak adlandırılır. Erken budamada ağacın büyümesi erken durdurulur ancak genel olarak uygulamalarda bu erken budama zamanına karar verilmediği için bu yaklaşım pek tercih edilmez. Geç budama yöntemi ağacın tamamlanmasından sonra ağaçtaki gereksiz kısımların

çıkarılmasına dayanır ve genellikle bu yöntem daha çok kullanılmaktadır. Karar ağacının ilk hücresi kök olarak bilinmektedir. Karar ağacı algoritmasından alınacak sonucun iyi olması, karar ağacına ait kökün veri setini ne kadar temsil ettiği ile doğrudan ilişkilidir. Karar ağacında en sık kullanılan öznitelik seçim ölçütleri Gini ve Bilgi kazanımıdır. Bilgi kazanımı entropi tabanlıdır. Gini ise her sınıf için hesaplanmakta ve $[0,1]$ değer aralığında bir sonuç alınmaktadır. Elde edilen değer 0'a yaklaştıkça daha iyi bir ayırım yapılmaktadır. Gini değeri hesaplanmasına ait matematiksel gösterim "Eş. 4.4'te" verilmiştir. Eşitlikte verilen p_i değeri, i sınıfının gerçekleşme olasılığını vermektedir. Gerçekleşme olasılığı her sınıf için hesaplandıktan sonra elde edilen sonuçların karelerinin toplamı 1'den çıkarılmaktadır. Sınıfların hepsine ait Gini değerlerine bakıldığında hangi değer 0'a yakınsa kök olarak o seçilerek algoritma başlatılmaktadır [29].

$$Gini = 1 - \sum_{i=1}^n p_i^2 \quad (4.4)$$


Karar ağacı algoritmaları sınıflandırma problemlerinin yanı sıra regresyon problemlerinde de kullanılmaktadır. Veri ön işleme çalışmasına çok fazla ihtiyaç duymadığı ve hesaplama maliyeti düşük olduğu için veri sayısının büyük olduğu çalışmalarda tercih sebebi olmaktadır.



Şekil 4.9. Karar ağacı algoritması (KAA)

4.1.6. Rassal orman algoritması


Sınıflandırma işlemi yapılırken, birden fazla karar ağacı üreterek normal karar ağacı algoritmasında meydana gelebilecek olan aşırı uyumun önüne geçerek daha yüksek performansta modellerin üretilmesini amaçlayan bir algoritmadır. Rassal orman algoritmasındaki ağaçlardan oluşan ormanlar, her ağacın ormandaki tüm ağaçlar için aynı dağılıma sahip bağımsız olarak örneklenen rastgele bir vektörün değerlerine bağlı olacağı şekilde ağaç tahmin edicilerinin birleşimidir [30]. Rassal orman algoritması da karar ağacı algoritmalarından oluşmasından dolayı hem sınıflandırma hem de regresyon problemlerinde kullanılabilen bir denetimli öğrenme algoritmasıdır. Eğitim veri setinde bulunan en önemli özellikler, verilerin doğrusal olarak ayrılıp ayrılmamasından bağımsız oluşturulan karar ağaçları ile çıkarılmaktadır. Rassal orman algoritmasında bulunan her bir karar ağacı bağlı olduğu veri setinden rastgele seçilmiş alt kümelerdir. Bu algoritmayı karar ağacı algoritmalarından ayıran en temel özellikler köklerden oluşan bir düğümü alt düğümlere ayırırken en önemli özelliği bulmak yerine rastgele bir özellik alt kümesi içinde en önemli özelliği bulmaya çalışması ve karar ağaçlarının en geniş hali ile bırakılıp budanmamasıdır. [20] .



Şekil 4.10. Rassal orman algoritması (RO)

4.1.7. K-En yakın komşu algoritması

K-En yakın komşu algoritması uygulaması kolay, parametrik olmayan, denetimli ve örnek tabanlı bir algoritmadır. Hem sınıflandırma hem de regresyon problemleri için kullanılabilir. Örnek tabanlı algoritmalarda yeni karşılaşılan bir örnek sınıflandırılırken eğitim veri seti içerisinde yer alan örnekler ile benzerliğine bakılmaktadır. Bu sebeple bu algortmada öğrenme işlemi eğitim veri setinde yer alan veriler temel alınarak gerçekleştirilmektedir [31]. Yeni verinin, mevcut verilere olan uzaklığının hesaplanması ve algoritma çalışırken belirlenen k sayıda yakın komşuluğuna bakılabilmesi için çeşitli uzaklık fonksiyonları kullanılmaktadır. Veri setine eklenen yeni bir örneğin sınıflandırılması, uzaklığın hesaplanması ve tüm komşuluklara bakılması sebebi ile çok fazla zaman almaktadır. Uzaklık hesaplaması yapılırken genellikle Öklid uzaklığı kullanılmaktadır. Bu uzaklık hesaplamasına alternatif olarak Minkowski, Manhattan, Mahalanobis uzaklıkları da kullanılmaktadır. Uzaklık hesabı yapılırken veri setindeki bazı özellikler baskın olmaktadır ve bu baskın değerlerin normalize edilmesi sınıflandırma başarısında önemli rol oynamaktadır. Algoritmada oluşturulan model, eğitim veri setini ezberleyerek yeni bir veri geldiğinde ve tahmin yapması gerektiğinde seçilen mesafe metriğine bağlı olarak veri setindeki algortmaya verilen k sayısı kadar en yakın komşuları bulur ve verinin sınıflandırılmasını buradaki çoğunluğa göre belirler [20]. Uzaklık hesabı yapılırken bütün durumlara bakılmasından dolayı özellikle büyük boyutlu veriler için hesaplama maliyeti artmakta ve büyük bellek alanına ihtiyaç duyulmaktadır. Algoritma içerisinde seçilecek olan k değişkeni için sabit bir değer bulunmamaktadır. Veri setine göre farklı k değerleri denenip en uygun değerin bulunması elde edilecek sonucu iyileştirecektir. Bu algoritmanın performansı k komşu sayısı, uzaklık ölçütü ve öznitelik sayısı parametrelerine bağlı olarak etkilenir. K-EYK algoritması, diğer algoritmalar arasında en tembel algoritma olarak bilinir. Bunun en temel sebebi ise diğer algoritmalar gibi eğitim veri setinden özellik çıkarmak yerine veri setini ezberlemeye çalışmasıdır.



Şekil 4.11. K-En yakın komşu algoritması (K-EYK)

4.2. Sensör Verisi – Görüntü Dönüşümü Yaklaşımı

Sensör verisi – görüntü dönüşümü yaklaşımında temel amaç her frekans bandından alınan tek boyutlu verinin uzamsal ve zamansal değişim bilgisini içeren iki boyutlu bir görüntü formatında temsil edilmesidir. Temsil edilen görüntüler üç kanallı (KYM) ya da tek kanallı (gri) olabilmektedir. Verinin dönüşümden önceki tek boyutlu halinde kullanılamayan ya da elde edilemeyen öznitelikler görüntü dönüşümü ile ortaya çıkmakta ve elde edilen sınıflandırma başarımını artırmaktadır. Zaman serisi formatında sayılabilen veriler görüntüye dönüştürüldüğünde, bu resimler üzerinde görüntü işleme yöntemleri kullanılarak sınıflandırma işlemleri yapılabilmektedir. Bu dönüşüm üç farklı yöntem ile yapılabilmektedir. Bu yöntemler Gramian açısal alan dönüşümü (Gramian Angular Field – GAF), Markov geçiş alanı dönüşümü (Markov Transition Field – MTF) [32], [33] ve tekrarlanma grafiği (Recurrence Plot – RP) [34], [35] dönüşümüdür. Yapılan bu dönüşümler sonucunda elde edilecek olan görüntülerden Gramian açısal alan ve Markov geçiş alanı yöntemleri ile elde edilen görüntüler 3 kanallı renk haritası ile temsil edilirken, tekrarlanma grafiği yöntemi ile elde edilen görüntüler siyah ve beyaz olmak üzere 2 kanallı olarak temsil edilmektedir. 3 kanallı renk haritaları içerisinde yer alan kırmızı ve kırmızıya yakın olan renkler büyük genlikli değerleri temsil ederken, mavi ve maviye yakın olan renkler küçük genlikli değerleri temsil etmektedir. Tek kanallı temsil edilen görüntü siyah beyaz noktalar çizgiler ve desenlerden oluşmaktadır. Dönüşüme uğrayan verilerin zamansal ve uzamsal özellikleri birbirlerinden farklı olduğu için elde edilen görüntüler birbirlerinden farklılık göstermektedir. Elde edilen görüntü formatındaki veriler derin öğrenme algoritmalarının kullanımı mümkün kılmaktadır. Sensör verisi – görüntü dönüşümü yaklaşımını

matematiksel olarak ifade etmek için f fonksiyonu ve fonksiyon tabanlı eşleme “Eş. 4.5, Eş. 4.6, Eş. 4.7, Eş. 4.8 ve Eş. 4.9’da” gösterilmektedir.

$$f: \mathbb{R}^{1 \times n_i} \rightarrow \mathbb{R}^{n_o \times n_o} \quad (4.5)$$

$$Z = f(X) \text{ ve } X = f^{-1}(Z), x \in \mathbb{R}^{1 \times n_i}, z \in \mathbb{R}^{n_o \times n_o} \quad (4.6)$$

$$Z_{GAF} = f_{GAF}(X) \quad (4.7)$$

$$Z_{MTF} = f_{MTF}(X) \quad (4.8)$$

$$Z_{RP} = f_{RP}(X) \quad (4.9)$$

Yukarıdaki eşitliklerde n_o eşlemenin çıkış boyutunu, n_i eşlemenin giriş uzayındaki boyutunu, x giriş uzayı vektörünü, z eşleme uzayı tensörünü tanımlamaktadır. Her bir eşleme fonksiyonu (f_{GAF} , f_{MTF} , f_{RP}) vasıtasıyla farklı veri dönüşümleri elde edilmektedir.

4.2.1. Gramian açısıl alan dönüşümü

Gramian açısıl alan dönüşümü zaman serisi formundaki verilerin kartezyen koordinat düzlemi yerine polar koordinat düzleminde açısıl karşılıkları ile temsil edilmesine olanak sağlamaktadır. GAA, kutupsal koordinat tabanlı matrisle verileri görüntüye kodladığı için mutlak zamansal korelasyonu koruyabilmektedir [32]. GAA yönteminde dönüşüm için verilen her bir nokta yeniden ölçeklendirilerek $[-1,1]$ ya da $[0,1]$ aralığına düşürülmektedir. Bu ölçeklendirme adımının matematiksel temsili “Eş. 4.10” ve “Eş. 4.11’de” verilmektedir.

$$\tilde{x}_{-1}^i = \frac{(x_i - \max(X) + x_i - \min(X))}{\max(X) - \min(X)} \quad (4.10)$$

$$\tilde{x}_0^i = \frac{x_i - \min(X)}{\max(X) - \min(X)} \quad (4.11)$$

Yukarıdaki eşitlikte verilen x_i değeri zaman serisinde, “i” noktasındaki elemanın değerini (zaman damgası), $X = \{x^1, x^2, x^3, \dots, x^m\}$ zaman serisinin vektör olarak gösterimini, m değeri

vektör olarak ifade edilen zaman serisinin uzunluğunu göstermektedir. “Eş. 4.10’da” verinin $[-1,1]$ aralığına, “Eş. 4.11’de” ise veri değerlerinin $[0,1]$ aralığına ölçeklenmesi, sırası ile “-1” ve “0” alt indisleri ile gösterilmiştir. Gramian açısıl alan dönüşümü iki farklı yöntem ile yapılmaktadır. Bu yöntemler Gramian Açısıl Toplama Alanı ve Gramian Açısıl Fark Alanı olarak bilinmektedir. Bu iki yöntem arasındaki fark Gramian Açısıl Toplama Alanının kosinüs fonksiyonlarına, Gramian Açısıl Fark Alanının ise sinüs fonksiyonlarına dayanan trigonometrik fonksiyonlara dönüştürülmesidir. Verilerin yukarıda verilen aralıklara ölçeklenmesi sonrasında elde edilen yeni verileri, kutupsal koordinatlara kodlamak için açısıl olarak kosinüs fonksiyonu ile hesap yapılmaktadır. Zaman damgası olarak da yarıçap değerinin kodlanması ile kutupsal koordinat düzleminde ifade tamamlanmaktadır. Dönüşümün matematiksel ifadeleri “Eş. 4.12”, “Eş. 4.13” ve “Eş. 4.14’te” verilmiştir.

$$X^{Polar} = \begin{cases} \phi = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, t_i \in \mathbb{N} \end{cases} \quad (4.12)$$

$$GATA = \begin{bmatrix} \cos(\phi_1 + \phi_1^N) & \cdots & \cos(\phi_1 + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (4.13)$$


$$GATA = \tilde{X}' \cdot \tilde{X} - \sqrt{I - \tilde{X}^2}' \cdot \sqrt{I - \tilde{X}^2} \quad (4.14)$$

Bu eşitliklerde, dönüşüm sonrasında elde edilen ϕ kutupsal koordinat düzlemindeki açı değerini, t_i zaman damgasını, r kutupsal koordinat düzleminde yarıçap değerini, N kutupsal koordinat düzleminin genişliğini düzenlemek için sabit bir parametre değerini temsil etmektedir. X^{Polar} dönüşüm sonrasında elde edilen matrisi, GATA ise Gramian açısıl toplama alanını ifade etmektedir. Benzer şekilde önişleme sonrasında, Gramian açısıl fark alanı (GAFA) ise “Eş. 4.15” ve “Eş. 4.16” ile elde edilebilmektedir. Gramian açısıl alan dönüşümü yönteminden sonra elde edilen matris çift yönlü kullanılabilen bire bir ve örten bir matristir. Ters fonksiyon olarak kullanıldığında, orijinal verilerin elde edilmesine olanak sağlamaktadır.

$$GAFA = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \vdots & \ddots & \vdots \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{bmatrix} \quad (4.15)$$

$$GAFA = \sqrt{I - \tilde{X}^2} \cdot \tilde{X} - \tilde{X}' \cdot \sqrt{I - \tilde{X}^2} \quad (4.16)$$

Bu adımın sonunda zaman serisi formatındaki veri, 3 kanallı KYM renk kodlaması içeren bir resim formatında kodlanarak dönüşüm işlemi tamamlanmış olur. Açıklanan yöntemin bir uygulaması Şekil 4.12’de gösterilmektedir.



Şekil 4.12. Gramian açısıl alan dönüşüm yöntemi

4.2.2. Markov geçiş alanı dönüşümü

Markov geçiş alanı dönüşümü, verilen zaman serisi formatındaki veri setinde bulunan herhangi iki ardışık nokta arasındaki geçiş olasılığını zamansal olarak matrise dağıtan bir yöntemdir. Verilen zaman serisinin zaman adımları arasındaki çok ölçekli geçiş olasılıklarını temsil edebilir [36]. İlk olarak M veri setinde, A dağılım dilimlerinin (kuantil kutularının) tanımlanması yapılmaktadır. Veri setindeki her m_i ile buna karşılık gelen a_i dilimleri tanımlanmaktadır. Bu tanımlama eğitim setindeki her ardışık iki nokta arasında yapılmaktadır ve bu “Eş. 4.17” ve “Eş. 4.18’de” gösterilmiştir [37]. Zaman eksenı boyunca oluşan dağılım dilimlerine markov zinciri adı verilmektedir. Bu markov zinciri şeklinde olan dağılım dilimlerinin arasındaki geçişler hesaplanarak A x A ağırlıklı bir yakınlık matrisi oluşturulmaktadır. Oluşturulan bu matristeki her $w_{i,j}$, a_j dağılım dilimine ait bir nokta ve o noktayı takip eden a_i dağılım diliminin bir noktasının gelme sıklığı ile belirlenmektedir. Bu belirleme işlemi matristeki her bir eleman için yapılmaktadır. Bu işlem bittikten sonra elde edilen matris $\sum_j w_{ij} = 1$ eşitliğine göre normalize edilmektedir. Bu normalizasyon işlemi sonrası Markov geçiş matrisi elde edilmektedir. Elde edilen markov geçiş matrisi veri setindeki her nokta çifti için, noktaların ait olduğu iki kuantil kutuları arasındaki geçiş olasılığını içerir. Markov geçiş matrisi x’in dağılımına duyarsız ve artık


zamandan bağımsızdır [32]. Yukarıda bahsi geçen Gramian Açısal Alan yöntemine ters olarak, orijinal verilere erişim Markov geçiş alanı yönteminde imkansız olmaktadır. Verilerin A dağılım dilimlerine bölünmesiyle elde edilen Markov geçiş matrisi “Eş. 4.19’da” gösterilmektedir.

$$\forall (i, j) \in [[1, A + 1]], \hat{w}_{ij} = \text{geçiş sayısı } a_i \rightarrow a_j \quad (4.17)$$

$$\forall (i, j) \in [[1, A + 1]], w_{ij} = \frac{\hat{w}_{ij}}{\sum_j \hat{w}_{ij}} \quad (4.18)$$

$$A = \begin{bmatrix} w_{ij|x_1 \in a_i, x_1 \in a_j} & \cdots & w_{ij|x_1 \in a_i, x_n \in a_j} \\ w_{ij|x_2 \in a_i, x_1 \in a_j} & \cdots & w_{ij|x_2 \in a_i, x_n \in a_j} \\ \vdots & \ddots & \vdots \\ w_{ij|x_n \in a_i, x_1 \in a_j} & \cdots & w_{ij|x_n \in a_i, x_n \in a_j} \end{bmatrix} \quad (4.19)$$

Markov geçiş matrisi, 3 kanallı renk bilgisi içeren resim formatına kodlanarak dönüşüm işlemi tamamlanmaktadır. MGA, zamansal aralıktaki ayrıntıları Markov geçiş olasılıklarını kullanarak koruyabilmektedir. Açıklanan bu yöntemin örnek bir uygulaması Şekil 4.13’te verildiği gibidir.



Şekil 4.13. Markov geçiş alanı dönüşümü


4.2.3. Tekrarlanma grafiği dönüşümü

Tekrarlanma grafiği dönüşümü, zaman serisi formatındaki verilerde tekrarlayan davranışları araştırmaya izin veren ve bu verilerin doğrusal olmayan analizi için kullanılan gelişmiş bir yöntemdir. Yukarıda bahsi geçen dönüştürme yöntemlerinden farklı olarak sadece zaman serisi formatındaki veriler ile değil, periyodik veriler, döngüler gibi tekrarlayan süreçler, kısa ve durağan olmayan veriler içinde kullanılabilen tekrarlanma grafiği dönüşümü yöntemi, bu döngüleri ve periyodik verileri iki boyutlu ve tek kanallı bir şekilde görselleştirmektedir.

Tekrarlanma grafiklerinin temel amacı, yüksek boyutlu faz uzayı yörüngelerini görsel olarak incelemektir. Tekrarlanma grafiği yönteminde görüntü veri setindeki her bir noktanın, veri setine olan uzaklığı hesaplanarak oluşturulur. Zamana bağlı bir davranışın görselleştirildiği bu yöntemde, görselleştirmenin ana adımı dikkate alınan durumların sayısı R olan bir veri setinden elde edilen $R \times R$ boyutlu matrisin hesaplanmasıdır. [34]. Hesaplanan bu matrisin elemanları dinamik bir sistemin durumunun tekrarlandığı zamanlara karşılık gelmektedir. Tekrarlanma grafiğinde, faz uzayı yörüngesi faz uzayında aynı alan her ziyaret edildiğinde noktalar, çizgiler ve küçük desenler ortaya çıkmaktadır. Ortaya çıkan bu noktalar, çizgiler ve desenler ile x_i durumlarının tekrarının görselleştirildiği bir araç olan tekrarlanma grafiği, m boyutlu faz uzay yörüngesinin ve tekrarlarının, iki boyutlu bir şekilde temsil edilmesini sağlar. Aynı durumun benzer şekilde ancak farklı zamanlarda tekrarlanması ile oluşturulan iki boyutlu kare matris içinde bir ve sıfır değerleri (grafikteki siyah ve beyaz noktalar) işaretlenir. Dönüşüm işlemi elde edilen matrisin, 2 kanallı renk kodlaması içeren bir resim formatında kodlanması ile tamamlanmaktadır. Tekrarlanma grafiğinin matematiksel olarak gösterimi ise “Eş. 4.20’de” gösterilmiştir. Eşitlikte verilen ε tanımlanmış eşik değer, R hesaplanacak veri sayısı, β basamak fonksiyonu olarak tanımlanmaktadır.

$$\mathbf{T}_{i,j} = \beta(\varepsilon - \|\vec{x}_i - \vec{x}_j\|), \quad i, j = 1 \dots R \quad (4.20)$$

Tekrarlanma grafikleri ile elde edilen görüntüler siyah-beyaz olmasından dolayı yukarıda bahsi geçen gramian açısal alan ve markov geçiş alanı yöntemlerindeki gibi kolayca tanımlanamazlar. Ancak kullanılacak olan evrişimli sinir ağı yöntemleri bu görselleri kategorilere ayırmak ve özelliklerini öğrenmek için kullanılabilir. Açıklanan yöntemin bir uygulaması Şekil 4.14’te verilmiştir.



Şekil 4.14. Tekrarlanma grafiği dönüşüm yöntemi

4.3. Tekil Değer Ayırışımı Yöntemi

Tekil değer ayırışımı yöntemi son zamanlarda farklı görüntü türlerini işlemek için en bilinen ve kullanılan matris ayırıştırma yöntemidir. Lineer cebir konusunda kullanılmakta ve reel veya karmaşık matrisler üzerinde ayırıştırma yapmaktadır. TDA yöntemi kavramsallığı ve kararlılığı sebebi ile giderek daha da popüler hale gelmektedir [38]. Temelde kendisine verilen matrisi 3 parçaya ayırmakta ve bu 3 parça matristen tekrar aynı matrisi elde edebilmektedir. Genellikle veriyi sıkıştırma, gürültülerini temizleme ve veriye ait en ilgi çekici özellikleri ortaya çıkarma ve veri azaltma için kullanılmaktadır. TDA yöntemi belirli bir eşeğin altındaki özellikleri göz ardı ederek veri setindeki en önemli olan özelliklerin ortaya çıkmasını sağlarken bu özellikler ile veri setindeki değerler arasındaki ilgili ilişkileri her zaman korumaktadır. M ayırştırmak istediğimiz bir matris olduğunda, bu ayırıştırma işlemine ait matematiksel gösterim “Eş. 4.21’de” verilmiştir.

$$M = U \cdot \Sigma \cdot V^T \quad (4.21)$$

M matrisinin sol tekil vektörleri U matrisinin sütunlarını, sağ tekil vektörleri V matrisinin sütunlarını oluşturmaktadır. Σ ise köşegen bir matris olup boyutları M matrisi ile aynıdır. Σ matrisinde M matrisinin tekil değerleri köşegen üzerinde azalan sırada gitmektedir. U ve V matrisleri, M matrisinin öz vektör matrisleri, Σ ise özdeğer matrisi olmaktadır. U matrisinin sütunları sol tekil vektörler olarak bilinirken, V matrisinin sütunları sağ tekil vektörler olarak

bilinmektedir. Matris U , M ve M^T matrislerinin çarpımının öz vektörlerinin, matris V ise M^T ve M matrislerinin çarpımının öz vektörlerinin sonucu olmaktadır. M matrisi $m \geq n$ olmak üzere $m \times n$ boyutlu bir matris olarak kabul edilmektedir [39]. $m \times n$ boyutlu M matrisinin ayrıştığı 3 matrisin boyutları U matrisi $m \times m$, V matrisi $n \times n$, Σ matrisi ise $m \times n$ boyutunda olacaktır. [38] Bu çalışmada TDA yönteminin tercih edilme sebebi ise; CNN mimarisinin yapısı gereği seyrek veri ile daha iyi çalışacak olmasıdır. Bu sebeple veriye ait en dikkat çekici özellikleri bulabilmek için tekil değer ayrışımı yöntemi kullanılmıştır. TDA ile ayrıştırıldıktan sonra görüntü birleştirme yöntemi ile elde edilen veriler üzerinde CNN mimarisi ile çalışıldığında literatürde bilinen en yüksek sonuç elde edilmiştir.

4.4. Dönüştürülmüş Görüntü Verisinin Birleştirilmesi

Önceki bölümlerde açıklandığı üzere veriye uygulanan her matematiksel dönüşümden sonra kullanılan dönüşüm yöntemine göre farklı matrisler elde edilmektedir. Her bir veriye uygulanan 3 farklı matematiksel dönüşüm yönteminden 3 farklı sonuç ve 3 farklı görüntü veri seti elde edilmiştir.

A_{GAA} , A_{MGA} ve A_{TG} matrisleri yukarıda bahsi geçen dönüşüm yöntemleri ile elde edilen $M \times M$ boyutlu matrislerden oluşmaktadır ($A_{GAA}, A_{MGA}, A_{TG} \in \mathbb{R}^{M \times M}$). A_{Merged} matrisi ise her bir matrisin farklı bir renk kanalına verilmesi ile $M \times M \times 3$ matrisinden oluşmaktadır ($A_{Merged} \in \mathbb{R}^{M \times M \times 3}$). Görüntü birleştirmedeki temel amaç farklı dönüşüm yöntemlerinden elde edilen özellikleri birleştirerek tek bir görüntüde daha fazla sayıda özellik elde etmektir.

$$A_{Birleşim}^{i,j,1} = A_{GAA}^{i,j} \quad (4.22)$$

$$A_{Birleşim}^{i,j,2} = A_{MGA}^{i,j} \quad (4.23)$$

$$A_{Birleşim}^{i,j,3} = A_{TG}^{i,j} \quad (4.24)$$


Yukarıda verilen eşitliklerde “Eş. 4.22”, “Eş. 4.23” ve “Eş. 4.24” sırası ile i ve j değerleri matrisin satır ve sütun indeksleridir. 1, 2 ve 3 değerleri ise birleşecek olan görüntüdeki hangi kanala hangi dönüşüm yönteminin ekleneceğini belirlemektedir. Bu sayılar sırası ile Kırmızı, Yeşil ve Mavi

kanalları temsil etmektedir. Bu işlemin bu tez çalışmasında kullanılan veri setindeki tüm verilere uygulanması ile 3 farklı dönüşüm yönteminden elde edilen özellikleri içeren görüntü formatında yeni tek bir veri seti oluşturulmuştur.

4.5. Evrişimli Sinir Ağı Mimarisi

Evrişimli sinir ağı (Convolutional Neural Network / CNN) yapay sinir ağlarının özel bir türüdür. Görüntü sınıflandırma problemleri başta olmak üzere, ses işleme ve bunlara benzer veri dizilerini işleme problemlerinde, görüntü renklendirilmesi ve dudak okuma ile sessiz videolara ses eklenmesi gibi problemlerde yaygın olarak kullanılan çok katmanlı algılayıcıların bir türü olan derin öğrenme mimarisidir. Gelişmiş öğrenme yeteneklerine sahip olması sayesinde, bu mimari ile yapılan çalışmalarda gerekli ön işlemenin çok daha az olması, özellik çıkarımının mimari tarafından yapılması bu mimarinin en büyük avantajlarından olarak görülmektedir. Evrişimli sinir ağı, klasik sinir ağı yapısına benzer şekilde öğrenilebilir ağırlıklara sahip nöronlardan oluşmaktadır. Bu nöronlar girişleri alıp, birleştirip ve genellikle lineer olmayan bir fonksiyon ile çıkış üretmektedirler. Evrişimli sinir ağı modeli, özellik çıkarımı ve sınıflandırıcının birleşimi olarak düşünülebilmektedir. Evrişimli sinir ağı 3 temel katmana sahiptir. Bu katmanlar: Evrişim (Convolutional), Havuzlama (Pooling) ve Tam Bağlı (Fully Connected) olarak sıralanmaktadır [40]. Bu katmanlardan evrişim ve havuzlama katmanı özellik çıkarımı işlemlerini yaparken, tam bağlı katman bir sınıflandırıcı olarak çalışmaktadır ve girişte modele verilen görüntünün hangi sınıfa ait olduğunun olasılığını hesaplamaktadır. Evrişimli sinir ağına ait temel fonksiyon “Eş. 4.25’te” verildiği gibidir. Bu eşitlikte verilen i girdi olarak verilen görüntüleri, w ağırlıkları ve biası içeren parametreleri, o çıkışı göstermektedir.


$$o = f(i, w) \quad (4.25)$$



Şekil 4.15. Örnek bir evrişimli sinir ağı mimari yapısı

Evrişim katmanı


ESA mimarisinde en temel blok evrişim katmanıdır. Bu katmanda, filtre ve katmana verilen giriş verisi birleştirilmektedir. Filtrenin giriş olarak verilen görüntü üzerinde kaydırılması ile evrişim işlemi yapılmaktadır. Bu katmanın ana işlevi, bir önceki katmandan gelen özelliklerin yerel birleşimlerini tespit etmek ve görünümelerini bir özellik haritasına işlemektedir. Bu işlemi şu şekilde yapmaktadır: Görüntü üzerinde dolaştırılan filtre ile görüntünün, birbirine karşılık gelen elemanları ile yapılan matris çarpımının sonucu, oluşturulacak olan özellik harita matrisinin bir elemanını oluşturmaktadır. Bu işlem tüm giriş verisi üzerinde tamamlandığında çıktı olarak özellik haritası (feature map) oluşturulmaktadır. Oluşturulan bu özellik haritasında, özelliğin görüntüde nerede meydana geldiği ve eşleştiği filtreye ne kadar iyi karşılık geldiği bilgisi tutulmaktadır. Kullanılan filtre boyutları olarak genelde 3x3, 5x5, 7x7 boyutunda olmaktadır. Filtre boyutlarının tek sayı olarak seçilmesindeki sebep girdi olarak verilen görüntüdeki kenarları bulma sırasında işlem yapılan pikselin sağ-sol, üst-alt olarak tamamının taranabilmesidir. Filtre boyutu büyüdükçe çıkarılacak olan özellik haritasının boyutu küçülmektedir. Bu küçülme bilgi kaybına yol açacağı için genel olarak 3x3 gibi küçük boyutlu filtreler kullanılmaktadır. Evrişim katmanından elde edilen sonuç aktivasyon fonksiyonuna gönderilmektedir. Aktivasyon fonksiyonları evrişimli sinir ağı gibi çok katmanlı ağlarda doğrusal olmayan dönüşüm işlemleri için kullanılmaktadır. Bunun asıl sebebi derin öğrenme yöntemlerinin doğrusal olmayan yapıdaki problemlerin çözümünde daha başarılı olmalarıdır. Kullanılacak olan aktivasyon fonksiyonları mimarideki probleme özgü olarak seçilmektedir [41]. Örnek bir aktivasyon fonksiyonu Şekil 4.16'da görüldüğü gibi olmaktadır.



Şekil 4.16. Örnek bir evrişim katmanı yapısı

Havuzlama katmanı


Havuzlama katmanı, evrişim katmanından sonra boyut indirgeme için uygulanmaktadır. Havuzlama katmanı ESA'nın öğrenmesi gereken parametre sayısını azaltma işlemi yapmaktadır. Parametre sayısı azaltılması, evrişim katmanının çıkışı olan özellik haritasının yüksekliği ve genişliği düşürülerek yapılmaktadır. Bu işlemde derinlik sabit kalmaktadır. En yaygın kullanılan yöntemi max pooling adı verilen yöntemdir. Havuzlama katmanı gerçekleştirilirken bir boyut ve doldurma(padding) değeri verilmektedir. Doldurma değeri katmana verilen giriş ile aynı boyutta özellik haritası oluşturmak için kullanılmaktadır [41]. Matrisin etrafına 0 değerine sahip hücreler eklenerek yapılmaktadır. Havuzlama katmanının boyutu genellikle girişte kendisine verilen özellik haritasının boyutunu yarı yarıya indirecek şekilde seçilmektedir.



Şekil 4.17. Örnek bir havuzlama katmanı yapısı

Tam bağlı katman

ESA mimarisi içerisinde peş peşe birden fazla evrişim ve havuzlama katmanı bulunabilmektedir. Bu katmanlar mimari içerisinde tamamlandıktan sonra tam bağlı katman eklenmektedir. Tam bağlı katmanda yapılacak olan sınıflandırmaya ait olasılıklar tutulmaktadır. Havuzlama katmanının çıktısı olarak verilen, boyutu giriş boyutuna göre yarıya indirilmiş olan özellik haritası 3 katman olarak tam bağlı katmana girdi olarak verilirken, tam bağlı katmandaki işlemlerden sonra çıkış vektörü tek katmanlı olmaktadır.



Şekil 4.18. Örnek bir tam bağlı katman yapısı

Evrişim katmanında oluşturulan özellik haritası, evrişim katmanlarından geçerek havuzlama katmanlarına iletilmekte ve bu yapı kurulan mimari boyunca devam etmektedir. Son havuzlama katmanından özellik haritası çıktığında düzleştirilip tam bağlı katmana gönderilmektedir [42]. Evrişim katmanının yapısına ait matematiksel açıklama “Eş. 4.26” ve “Eş. 4.27”de” verilmiştir.

$$Y_i^{(k)} = B_i^{(k)} + \sum_{j=1}^{m_1^{(k-1)}} F_{i,j}^{(k)} * Y_j^{(k-1)} \quad (4.26)$$

$$O_i^{(k)} = f(Y_i^{(k)}) \quad (4.27)$$

Yukarıda verilen denklemde $Y_i^{(k)}$, k katmanındaki i 'ninci çıkış değerini, $m_1^{(k)}$ öznitelik haritası için filtre değerini göstermektedir. $O_i^{(k)}$ çıkış katmanındaki değeri, $B_i^{(k)}$ bias matrisi değerlerini, $F_{i,j}^{(k)}$ ise katman $(k-1)$ deki j ve i alt indislerine ait öznitelik haritası arasında bağlantıyı sağlayan $(2h_1^{(k)} + 1) \times (2h_2^{(k)} + 1)$ boyutlarında filtreyi ve f ise aktivasyon fonksiyonunu göstermektedir.

Tüm mimari oluşturulurken katmanların sıralı olarak bir araya getirilmesi ile mimariye girdi olarak verilen görüntünün içerdiği bilgi hiyerarşik olarak bölünmektedir. Oluşturulan mimaride çıkış katmanındaki sınıflandırmada olasılık dağılımının hesaplanması için bir aktivasyon fonksiyonu kullanılmaktadır ve bu aktivasyon fonksiyonu ile mimari tamamlanmış olur.

Evrişimli sinir ağı mimarisinde oluşturulan modelin yüksek başarımlı elde etmesini sağlamak için algoritmayı oluşturan kişiler tarafından değerleri belirlenen ve bu değerlerin veri setine ve probleme göre değişiklik gösterdiği bazı hiper parametreler kullanılmaktadır. Bu tez çalışmasında başarımın artması için kullanılan ve değiştirilen hiper parametreler; aktivasyon fonksiyonu, optimizasyon algoritması, devir sayısı (epoch), iterasyon ve paket boyutu, düzensizleştirme (regularization) ve ağırlık başlangıç değerleri olarak sıralanmaktadır. Bu hiper parametreler arasından her bir hiper parametre türünden seçilene ait açıklamalara aşağıda yer verilmektedir.

Aktivasyon fonksiyonu - Softmax aktivasyon fonksiyonu

Softmax aktivasyon fonksiyonu sınıflandırma problemlerinde kullanılmaktadır ve çıkışın sınıflara ait olma olasılığını vermektedir. Mimariye verilen girdinin belirli bir sınıfa ait olma olasılığını 0-1 aralığında bir değer üreterek belirlemektedir. Bir veri için üreteceği değerlerin toplamı 1'dir. Genellikle çıkış nöron sayısı sınıflandırılmak istenen sınıf etiketi sayısı kadardır [43]. Softmax fonksiyonu matematiksel tanımı “Eş. 4.28”, “Eş. 4.29” ve “Eş. 4.30'da” verildiği gibidir. Softmax aktivasyon fonksiyonu S boyutlu bir uzaydan d vektörünü alır ve bu vektörün S olasılık değerlerinden oluşan olasılık dağılımına çevrilmesini sağlamaktadır. Aktivasyon fonksiyonu uygulanmadan önce S uzayı içinden seçilen d vektörü negatif ya da pozitif bir değer olabilmektedir ancak aktivasyon fonksiyonu uygulandıktan sonra d vektörü 0 – 1 arası bir değer olmaktadır.

$$\sigma: \mathbb{R}^S \rightarrow [0,1]^S \quad (4.28)$$


$$\sigma(\mathbf{d})_i = \frac{e^{d_i}}{\sum_{j=1}^S e^{d_j}} \text{ for } i = 1, \dots, S \quad (4.29)$$

$$\mathbf{d} = (d_1, \dots, d_S) \in \mathbb{R}^S \quad (4.30)$$

Aktivasyon fonksiyonu – Rectified Linear Unit (ReLU) Aktivasyon Fonksiyonu

ReLU aktivasyon fonksiyonu doğrusal aktivasyon fonksiyonları arasında yer almaktadır. Fonksiyonda pozitif girişler doğrudan, negatif girişler ise 0 olarak çıkmaktadır. ReLU aktivasyon fonksiyonunun değer aralığı $[0, +\infty]$ olarak bilinmektedir. Negatif değerlerin 0 olarak çıkması bu fonksiyonun daha hızlı çalışmasını sağlamaktadır. Hesaplama maliyetinin diğer aktivasyon fonksiyonlarına göre daha az olması ve daha iyi performans elde etmesi sebebi ile en çok tercih edilen aktivasyon fonksiyonu olmaktadır. ReLU aktivasyon fonksiyonuna ait çıkış işlemi “Eş. 4.31” ile tanımlanmaktadır. ReLU aktivasyon fonksiyonuna ait grafik ise Şekil 4.19’da verilmiştir [44] [45].

$$f(x) = x^+ = \max(0, x) \quad (4.31)$$




Şekil 4.19. ReLU aktivasyon fonksiyon grafiği

Aktivasyon fonksiyonu – Sigmoid aktivasyon fonksiyonu

Sigmoid aktivasyon fonksiyonu doğrusal olmayan aktivasyon fonksiyonları arasında yer almaktadır. Sigmoid fonksiyonu $[0,1]$ değer aralığında çıktı üreten olasılıksal bir yaklaşım sergilemektedir. İkili sınıflandırma problemlerinde başarı ile uygulanmaktadır. Sigmoid fonksiyonu genellikle daha az katmanlı mimarilerde kullanılmaktadır [46]. Sigmoid aktivasyon fonksiyonuna ait matematiksel gösterim “Eş. 4.32” ile tanımlanmaktadır [47].

$$f(x) = \frac{1}{(1+e^{-x})} \quad (4.32)$$



Şekil 4.20. Sigmoid aktivasyon fonksiyon grafiği

Optimizasyon algoritması - Adaptif Moment Tahmini optimizasyon algoritması

ADAM algoritması parametrelerin her birinin öğrenme oranlarını ve parametrelere ait momentum değişikliklerini önbellekte saklamaktadır. Geçmiş bütün eğitimlerin karelerini üssel olarak ağırlıklandırıp ortalamasını almaktadır. ADAM algoritması diğer optimizasyon algoritmalarından farkı olarak momentum değişikliklerini sonuca dahil etmektedir. ADAM algoritmasına ait matematiksel tanımlama “Eş. 4.33”, “Eş. 4.34” ve “Eş. 4.35’te” verilmiştir [45].

$$\begin{aligned} m_t &= \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t &= \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \end{aligned} \quad (4.33)$$

$$m'_t = \frac{m_t}{1 - \beta_1^t}, v'_t = \frac{v_t}{1 - \beta_2^t} \quad (4.34)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v'_t + \epsilon}} \hat{m}_t \quad (4.35)$$

Yukarıda verilen “Eş. 4.32’de” $\hat{m}_t$ önbellekte saklanacak olan momentum değişikliklerini, v_t geçmiş eğitimlerin karelerinin üssel olarak ağırlıklandırılan ortalamalarını

göstermektedir. Elde edilen bu değerler ile yapılan türev ile güncelleme işlemleri ise “Eş. 4.34” ve “Eş. 4.34’te” verilmiştir. “Eş. 4.34’te” verilen β_1^t ve β_2^t ‘de bulunan t değeri kuvvet olarak hesaba katılmaktadır. Bu iki ifade kullanılarak parametre güncellemesi yapılmaktadır bu güncellemenin matematiksel tanımı ise “Eş. 4.34’te” verilmiştir.

İkili çapraz entropi kayıp fonksiyonu

Kayıp fonksiyonları tasarlanan mimariye ait hata oranını veren ve aynı zamanda mimariye ait başarımın ölçülmesine yardımcı olan fonksiyonlardır. Oluşturulan derin sinir ağlarının son katmanlarında bulunmaktadırlar. İkili çapraz entropi kayıp fonksiyonu sınıflandırmanın iki sınıf arasında yapılacağı problemlerde kullanılmaktadır. Gerçekleştirilen bu tez çalışmasında kullanılan kayıp fonksiyonu çalışma sonunda verinin silindirik kaya ya da silindirik mayın olmasına göre 1 ve 0 şeklinde etiketleme yapmaktadır. İkili çapraz entropi kayıp fonksiyonuna ait matematiksel tanımlama “Eş. 4.36’da” verilmiştir [49].

$$BL(\hat{\mathbf{x}}, \mathbf{x}) = -\frac{1}{N} \sum_i^N [x_i \log \hat{x}_i + (1 - x_i) \log(1 - \hat{x}_i)] \quad (4.36)$$

Yukarıda verilen eşitlikte BL kayıp fonksiyonunun değerini, x_i veri setindeki i ’nci verinin etiket değerini $\hat{x}_i$ o veri için üretilen sonucu, N ise veri setindeki toplam veri sayısını göstermektedir.

Devir sayısı (epoch), iterasyon ve paket boyutu

Devir sayısı, modele girdi olarak verilen tüm verinin yalnızca bir kez sinir ağı üzerinden bir ileri ve bir geri aktarılması olarak bilinmektedir. Paket boyutu, tek bir grupta bulunan ileri ve geri yönde aktarılacak eğitim örneklerinin sayısı olarak bilinmektedir. Bir devirin tamamlanması için gereken paket sayısı iterasyonu vermektedir. Örneğin 5000 adet verinin bulunduğu bir veri setinde paket boyutu 50 seçilir ise bir devirin tamamlanması için 100 iterasyon gerekmektedir. Devir sayısı, iterasyon ve paket boyutlarının artması doğrudan sınıflandırma başarımını arttırmamaktadır. Veri setinin boyutuna göre seçilmez ise aşırı uyum ya da az öğrenme gerçekleşebilmektedir. Küçük boyutlu veri setlerinde paket boyutunun küçük tutulması başarımı arttırabilmektedir.

Düzenleştirme (Regularization)

Düzenleştirmenin asıl kullanım amacı oluşturulan sinir ağındaki aşırı uyumun önüne geçilmesi olarak bilinmektedir. Düzenleştirme, L1 düzenleştirmesi (Lasso Regression), L2 düzenleştirmesi (Ridge Regression) ve seyreltme katmanı (Dropout) ekleme ile yapılabilmektedir. L1 düzenleştirme yönteminin veri setindeki daha az önemli olan özelliklerinin katsayılarının sıfıra indirilmesi ile bu özellikleri kaldırıyor olması, L2 düzenleştirmesinden en temel farkı olarak bilinmektedir [50]. L1 ve L2 yöntemlerine ait matematiksel eşitlikler “Eş. 4.37” ve “Eş. 4.38” ile tanımlanmaktadır.

$$R_{L_1}(w) = \|W\| = \sum_{k=1}^Q w_k \quad (4.37)$$

$$R_{L_2}(w) = \|W\|^2 = \sum_{k=1}^Q w_k^2 \quad (4.38)$$

“Eş. 4.37’de” verilen ifadede görüldüğü üzere L1 düzenleştirmede maliyet fonksiyonuna düzenleştirme terimi olarak ağırlıkların mutlak değerlerinin toplamı, L2 düzenleştirmede ise her bir ağırlığın karelerinin toplamı verilmektedir [51]. Seyreltme katmanı sinir ağında bulunan nöronların rastgele bir şekilde çıkarılmasını sağlayarak aşırı uyumun önüne geçmeyi amaçlamaktadır. Birçok farklı ağ mimarisini üssel ve verimli bir şekilde birleştirmenin olası yolunu sağlamaktadır. Aynı zamanda seyreltme katmanının algoritmanın öğrenme hızını artırdığı bilinmektedir. Çıkarılacak olan bağlantıların oranı $[0,1]$ aralığında bir ondalık değer olarak seçilmektedir. Genellikle 0,5 olarak seçilmektedir [52].

Ağırlık başlangıç değerleri

Ağırlık başlangıç değerlerinin kullanılmasının amacı sinir ağında ileri geçiş sırasında aktivasyon fonksiyonlarının çıktılarını daha iyi duruma getirmektir. Bu tez çalışmasında ağırlık başlangıç değeri tanımlayıcıları olarak HeUniform, Glorot (Xavier) Normal ve Truncated Normal kullanılmıştır. Glorot normal sigmoid aktivasyon fonksiyonu ile HeUniform ise ReLU aktivasyon fonksiyonu ile daha iyi çalışacak şekilde tasarlanmıştır. ReLU aktivasyon fonksiyonları ile HeUniform kullanılmasının daha yüksek başarı sağladığı

başka çalışmalarda kanıtlanmaktadır [53]. Ağırlık başlangıç değerleri seçilirken sinir ağında kullanılan aktivasyon fonksiyonlarına göre seçilmiştir [54].

5. ÖNERİLEN YÖNTEM VE DENEYSEL DOĞRULAMA

Bu tez çalışması kapsamında öncelikle verinin temsili değiştirilmeden klasik makine öğrenme algoritmaları denenmiş daha sonrasında verinin temsiline değiştirilmesi ile elde edilmiş yeni görüntü veri setleri ile 4 adet yenilikçi yöntem önerilmiştir.


İlk olarak kullanılan makine öğrenme algoritmalarının hiperparametleri ve açıklamaları verilmiştir.

Destek vektör makinesi algoritması veri setinin yapısından dolayı doğrusal olmayan DVM yöntemi ile radyal tabanlı çekirdek fonksiyonu $C = 1,5$ parametresi ile kullanıldığında, diğer hiper parametre denemeleri arasından en yüksek başarı oranına ulaştığı gözlemlenmiştir. Doğrusal ayrımcılık analizi algoritmasında, veri setinin yapısı gereği tekil değer ayrışımı yöntemi kullanılarak kovaryans matrisi hesaplaması yapılmamıştır. Bu sebeple kovaryans depolaması false olarak seçilmiştir. Tekil değer ayrışımı yöntemi kullanıldığı için tolerans değeri $1,0e-5$ olarak seçilmiştir. Lojistik regresyon algoritması, bu çalışmada en yüksek performanslı sonuç için penaltı değeri L2 olarak seçilmiştir. Veri setinin boyutunun çok büyük olmaması ve ikili sınıflandırma problemi olmasından dolayı çözücü olarak 'liblinear' kullanılmıştır. Diğer parametreler aynı şekilde bırakılırken ılık başlama (warm start) değeri çözücü olarak doğrusal (liblinear) kullanıldığı için kullanılmamıştır. GaussianNB algoritmasında, önceki sınıflara ait olasılıklar belirtilmemiş ve hesaplama kararlılığı için varyanslara eklenecek olan yumuşatma değeri $1.0e-9$ olan varsayılan değeri ile alınmıştır. Karar ağacı algoritması uygulanırken, Gini indeksi, bir düğümü bölmek için gereken minimum örnek sayısını 2, bir yapraktaki minimum örnek sayısını ise 1 olarak kullanılmıştır. Herhangi bir maksimum derinlik parametresi verilmemiştir. Kullanılan rassal orman algoritmasında, entropi kriteri ile maksimum derinlik 15 verilerek maksimum örnek sayısı 5, bir düğümü bölecek minimum örnek sayısı 3 olacak şekilde ayarlanmıştır. Oluşturulacak ağaç sayısı 1000 olarak verilmiştir. Son olarak K-en yakın komşu algoritması ise veri setindeki verilerin yapısı ve boyutunun büyük olmamasından dolayı k değeri 1, ağırlık olarak 'uniform' değeri verilerek eğitildiğinde en yüksek performansın alınması sağlanmıştır.

Verinin temsiline değiştirilmesinden sonraki önerilen yenilikçi yöntem ile oluşturulan 4 farklı modele ait açıklamalar aşağıda verilmiştir.

Bu yöntemlerden ilki matematiksel dönüşüm yöntemleri olan gramian açılal alanı (GAA), markov geçiş alanı dönüşümü (MGA) ve tekrarlanma grafiği (TG) yöntemlerinin her biri ile tüm veri setine ait elemanların iki boyutlu görüntü temsiline çevrilmesi ile 3 farklı görüntü veri seti oluşturulmasıdır. Bu görüntü veri setleri mayın ve kaya şeklinde etiketlenerek sınıflara ayrılmıştır. Etiketlenmiş bu sınıflara ait veriler bölme metodu kullanılarak %67 eğitim, %33 test olacak şekilde bölünmüştür. Dizi formatında hazırlanmış olan veri setinde görüntü boyutlarını ayarlama ve veriyi normalize etme işlemleri yapılmıştır. Veri setinde kullanılacak olan görüntünün yüksekliği 224, genişliği 224 ve derinliği 3 olarak seçilmiştir. Boyutlandırma yapılırken elde ettiğimiz veriler 3 kanallı olduğu için burada görüntüye ait en ve boy pikselleri 224 olarak belirlenirken kanal numarası olarak 3 verilmiş bulunmaktadır. Verinin normalize edilmesi işleminde her bir görüntü verisi 3 kanallı (KYM) olmasından dolayı 0-255 arasında değerlere sahiptir. Bu değerlerin $[0,1]$ aralığına getirilmesi için veriler 255'e bölünmüş böylece istenilen aralığa getirilmiştir. Veriler eğitime başlanmadan önce paket boyutu 8 olarak belirlenmiştir. Elde edilen veriler oluşturulan evrişimli sinir ağı modeline verilerek eğitim başlatılmıştır. Oluşturulan evrişimli sinir ağı mimarisi, veri sayısının az olmasından dolayı oluşacak olan aşırı uyumun önüne geçebilmek için daha az karmaşık olacak şekilde oluşturulmuştur. Oluşturulan sıralı modelde ilk evrişim katmanına girdi boyutu elde edilen veri setindeki görüntülerin boyutları olan $224 \times 224 \times 3$ olarak belirtilmiştir. Evrişim katmanında görüntünün üzerinde dolaşması ve özellik haritasını çıkarması için verilecek olan filtre boyutu 3×3 olarak seçilmiştir. Bu boyutta 32 adet filtre uygulanmıştır. Girdi olarak verilecek görüntüden çıkarılacak olan özellik haritasının boyutunun küçük olmaması ve fazla özellik kaybı olmaması için filtre boyutu küçük seçilmiştir. Çıktı boyutunun girdi boyutuna eşit olması için doldurma (padding) yapılmıştır. Evrişim katmanından elde edilen çıktı ReLU aktivasyon fonksiyonuna gönderilmiştir. ReLU aktivasyon fonksiyonunun seçilmesinin sebebi, bu fonksiyonun eğitimde daha hızlı ve daha iyi sonuç vermesidir. ReLU aktivasyon fonksiyonu kullanılan tüm katmanlarda bu fonksiyona $1.0e-5$ oranı ile L1 düzenleştirmesi ve HeUniform ağırlık başlangıcı eklenmiştir. 2 adet aynı evrişim katmanından sonra bir adet havuzlama katmanı eklenmiştir. Bu katmanda verilen havuzlama boyutu 2, her adımda evrişim filtresinin hareket adım boyutu (stride) 2 olarak verilmiştir. Havuzlama katmanından sonra 3×3 boyutunda 64 adet filtre kullanılarak 2 adet evrişim katmanı ve sonrasında aynı havuzlama katmanı eklenmiştir. Gerçekleşebilecek olası aşırı uyumun önüne geçilmesi için seyreltme(dropout) katmanı eklenmiştir. Seyreltme katmanının katsayısı 0.3 olarak belirlenmiştir. Filtre sayısı 128'e çıkarılarak 3 adet daha evrişim katmanı ve bir adet havuzlama katmanı eklenmiştir.


Son olarak filtre sayısı 256'ya çıkarılmış ve 2 adet evrişim katmanı ve bir havuzlama katmanından sonra aynı özelliklere sahip bir seyreltme katmanı daha eklenip modelin özellik çıkarma kısmı tamamlanmıştır. Tam bağlı katmanlara geçip sırası ile olarak yoğunluğu 1024, 512 ve 1 olan 3 katman eklenmiştir. İlk iki katmanda aktivasyon fonksiyonu yine ReLU olarak tercih edilirken son katmanda sınıflandırma olasılıklarının görülmesi için softmax fonksiyonu kullanılarak model tamamlanmıştır. Modelin sonunda optimizasyon algoritması olarak ADAM algoritması $1.0e-5$ öğrenme oranı ile kullanılmıştır. ADAM algoritmasının seçilmesinin sebebi ise diğer optimizasyon algoritmalarından farklı olarak parametrelerin her birinin öğrenme oranları ile birlikte momentum değişikliklerini de tutmaktadır. Tamamlanan mimari ile 100 devir sayısı(epoch), 10 kat çapraz doğrulama ile eğitim gerçekleştirilmiştir. Önerilen bu yöntemle ait sonuçlar Bölüm 6'da Çizelge 6.2.'da, ESA mimarisi ise Şekil 5.1'de verilmiştir.



Şekil 5.1. Önerilen birinci yöntemle ait ESA mimarisi


İkinci yöntemde verinin temsili değiştirilip her bir matematiksel dönüşüm yöntemi ile görüntü verileri elde edildikten sonra, görüntülere ait daha fazla özelliğin kullanılması amacı ile üç veriden tek bir görüntü verisi elde edilmiştir. Verideki her bir eleman için 3 farklı yöntemden alınan görüntüler, kırmızı yeşil ve mavi olmak üzere üç farklı renk kanalına verilmiş ve böylece aynı veri için elde edilen 3 farklı görüntü sonucunda tek bir görüntü oluşturulmuştur. Elde edilen bu veri seti %80 eğitim, %20 test verisi olacak şekilde bölünmüştür. Oluşturulan bu görüntü birinci yöntemde kullanılan aynı ön işlemlerden geçirildikten sonra oluşturulan evrişimli sinir ağı mimarisi için hazırlanmıştır. Birinci yöntemdeki algoritma ile aşırı uyum gösterdiği (overfitting) gözlemlendiği için bu algortmada bazı hiper parametre değerleri değiştirilmiştir. ReLU aktivasyon fonksiyonu ile kullanılan L1 düzenlileştirilmesinin parametresi $1.0e-4$ olacak şekilde büyütülmüştür. Son evrişim katmanından sonra eklenen seyreltme katmanı oranı büyütülerek başarımlar artırılmıştır. Tam bağlı katmandaki çıkış katmanının aktivasyon fonksiyonu Sigmoid

aktivasyon fonksiyonu olarak değiştirilmiş ve aktivasyon fonksiyonun değiştirilmesi ile birlikte ağırlık başlangıç değeri de Glorot Normal olarak değiştirilmiştir. Devir sayısı (epoch) 15 e çapraz doğrulama değeri de 5'e düşürülmüştür. Paket boyutu 2'ye düşürülerek her iterasyondaki veri sayısını artırılması sağlanmıştır. Önerilen ikinci yönteme ait sonuçlar Bölüm 6 Çizelge 6.2'de, ESA mimarisi ise Şekil 5.2'de verilmiştir.




Şekil 5.2. Önerilen ikinci yönteme ait ESA mimarisi

Bu çalışma kapsamında önerilen üçüncü yöntemde verinin temsilinin değiştirilmesi için kullanılan matematiksel dönüşüm yöntemleri uygulanırken 2 aşama halinde gerçekleştirilmiştir. İlk aşamada matematiksel dönüşüm yöntemleri ile bir boyutlu sonar verileri matris formuna getirilmiştir. Elde edilen matris formundaki verilere tekil değer ayrışımı yöntemi uygulanarak her bir matristen öz değer ve öz vektör matrisleri oluşturularak 3 farklı matris elde edilmiştir. Elde edilen öz değer matrisleri matematiksel dönüşüm yöntemlerinin ikinci aşaması olan matris-görüntü dönüşümü ile her bir yöntem için farklı görüntülere dönüştürülmüştür. Tamamlanan bu dönüşüm sonrası tekil değer ayrışımı yöntemi ile elde edilen özellik matrislerine ait görüntüler elde edilmiştir. Elde edilen bu görüntüler %80 eğitim %20 test olacak şekilde bölünmüştür. Yukarıda bahsi geçen evrişimli sinir ağı mimarisine benzer şekilde kurulan mimaride devir sayısı (epoch) 40 olarak, paket boyutu 8 olarak 5 kat çapraz doğrulama ile model eğitilmiştir. Kayıp fonksiyonu olarak ikili çapraz entropi kullanılmıştır. Önerilen üçüncü yönteme ait sonuçlar Bölüm 6 Çizelge 6.3'te, ESA mimarisi ise Şekil 5.3'de verilmiştir.



Şekil 5.3. Önerilen üçüncü yönteme ait ESA mimarisi


Önerilen son yöntemde, üçüncü yöntemin başarımının artırılması için aynı yöntem ile oluşturulan görüntüler, görüntü birleştirme yöntemleri ile özellik artırımının sağlanabilmesi için tek bir görüntü haline getirilmiş ve yeni bir veri seti oluşturulmuştur. Oluşturulan veri seti tekrar %75 eğitim, %25 test olarak bölünmüştür. Üçüncü yöntemden farklı olarak seyreltme katmanları özellik çıkarımı olan katmanlar arasına değil, sınıflandırma olan tam bağlı katmanlar arasında oranı 0.3 olacak şekilde 2 tane yerleştirilmiştir. Tam bağlı katmanların boyutları 64, 48, 1 olarak belirlenmiştir. Tam bağlı katmanlarda yukarıdaki mimarilerden farklı olarak Truncated Normal parametresi kullanılmıştır. 40 devir sayısı (epoch) ve 5 kat çapraz doğrulama ile eğitim tamamlanmıştır. Önerilen son yönteme ait sonuçlar Bölüm 6 Çizelge 6.4’te, ESA mimarisi ise Şekil 5.4’de verilmiştir.



Şekil 5.4. Önerilen son yönteme ait ESA mimarisi

6. PERFORMANS ANALİZİ VE TARTIŞMA

Bu tez kapsamında önerilen yöntemler ve kullanılan makine öğrenme algoritmaları ile elde edilen sonuçlar iyi bilinen performans metrikleri ile karşılaştırılmıştır. Performans analizinin yapılması için kullanılan metrikler Doğruluk, Kesinlik, Geri getirme, F₁-Skor olarak seçilmiştir. Bu metrikler ile ilişkili verilen denklemlerde: GP, gerçek pozitif sayısını, GN, gerçek negatif sayısını, YP, yanlış pozitif sayısını, YN ise yanlış negatif sayısını temsil etmektedir. Veri setindeki tüm doğru olarak nitelendirilen sonuç sayısı P ile tüm yanlış olarak nitelendirilen sonuç sayısı N ile gösterilmektedir.



Şekil 6.1. Performans metrikleri

Doğruluk

Doğruluk, veri setindeki doğru tahmin edilen verilen tüm verilerin oranına bakılarak bulunmaktadır. Çok tercih edilen bir performans metriği olmasına rağmen eşit dağılıma sahip olmayan ve benzeri veri setlerinde tek başına yeterli olmamaktadır. Doğruluk hesaplanmasına ait matematiksel tanım “Eş. 6.1’de” verilmiştir [55].

$$\text{Doğruluk} = \frac{GP+GN}{P+N} = \frac{GP+GN}{GP+GN+YP+YN} \quad (6.1)$$

Kesinlik

Kesinlik, veri setindeki doğru tahmin edilen pozitif verilerin, toplam tahmin edilen pozitif verilere olan oranına bakılarak bulunmaktadır. Yanlış pozitif tahminlerinin getireceği maliyetin yüksek olduğu durumlarda daha önemli olmaktadır. Kesinlik hesaplamasına ait matematiksel tanım “Eş. 6.2’de” verilmiştir [56].

$$\text{Kesinlik} = \frac{GP}{GP+YP} \quad (6.2)$$

Geri Getirme

Geri getirme, veri setindeki doğru tahmin edilen pozitif verilerin, veri setinde bulunan toplam pozitif verilere olan oranına bakılarak bulunmaktadır. Verileri yanlış negatif olarak tahmin etmenin getireceği maliyetin yüksek olduğu durumlarda daha fazla öneme sahip olmaktadır. Geri getirme hesaplamasına ait matematiksel tanım “Eş. 6.3’te” verilmiştir [56].

$$\text{Geri Getirme} = \frac{GP}{GP+YN} \quad (6.3)$$

F₁ – Skor

F₁ – skor, kesinlik ve geri getirme metriklerinin harmonik ortalaması alınarak bulunmaktadır. Bu ortalama ile birlikte hem yanlış pozitifler hem de yanlış negatifler hesaba katılmaktadır. Doğruluk kadar anlaşılması kolay değildir ancak eşit olmayan bir sınıf dağılımına sahip olduğu durumlarda daha kullanışlı olmaktadır. [56] . F₁ – skor hesaplamasına ait matematiksel tanım “Eş. 6.4’te” verilmiştir.

$$F_1 = 2 \times \frac{\text{Geri Getirme} \times \text{Kesinlik}}{\text{Geri Getirme} + \text{Kesinlik}} \quad (6.4)$$

Çizelge 6.1’de sonar sinyallerinin bulunduğu veri setine uygulanan klasik makine öğrenme algoritmaları ile elde edilen sonuçlar verilmiştir. Karşılaştırılmanın tam yapılabilmesi için yukarıda verilen performans metriklerinin tamamı kullanılmıştır. Klasik makine öğrenme yöntemlerinin her biri çapraz doğrulama yöntemi ile birlikte en başarılı sonucu vermeleri için ayarlanan hiper-parametreler ile çalışılmış ve sonuçları raporlanmıştır. Elde edilen sonuçlar arasında en başarılı sonucun DVM algoritması ile elde edildiği gözlemlenmiştir.

Çizelge 6.1. Sonar sinyallerinin görüntü dönüşümü öncesi klasik makine öğrenme algoritmaları ile sınıflandırma sonuçları

Yöntem	Doğruluk (%)	Kesinlik (%)	Geri Getirme (%)	F ₁ Skor (%)
DVM	92,30	87,50	100,00	93,33
LR	90,38	87,09	96,42	91,51
RO	86,53	81,81	96,42	88,51
K-EYK	86,53	83,87	92,85	88,13
DAA	76,92	78,57	78,57	78,57
KA	75,00	75,86	78,57	77,19
GNB	67,30	78,94	53,57	63,82

Çizelge 6.2’de önerilen ilk yöntem ile elde edilen sonuçlar yer almaktadır. İlk yöntem ile elde edilen 3 farklı veri seti ile oluşturulan evrişimli sinir ağı modeli, aşırı uyumun önüne geçerken başarımın en fazla olacağı hiper-parametrelerin kullanımı ile çapraz doğrulama yöntemi ile eğitilmiştir.

Çizelge 6.2. Sensör verisi görüntü dönüşümü yöntemi ile elde edilen yeni veri seti ile ESA mimarisine ait en iyi sonuçlar

Yöntem	Doğruluk (%)	Kesinlik (%)	Geri Getirme (%)	F ₁ Skor (%)
TG	98,55	100,00	97,29	98,62
MGA	97,10	97,29	97,29	97,29
GAA	95,65	94,73	97,29	95,99

Çizelge 6.3.’te önerilen ilk yönteme ek olarak elde edilen 3 farklı veri setinin tek bir görüntüde 3 farklı kanala gönderilmesi ile elde edilen yeni veri setinin evrişimli sinir ağı modeli ile bu modele ve veri setine özgü olarak hazırlanan hiper parametreler ile eğitilmesi sonucu elde edilen sonuçlar verilmiştir.

Çizelge 6.3. Sensör verisi görüntü dönüşümü yöntemi sonrası görüntü birleştirme yöntemleri ile elde edilen yeni veri seti ile ESA mimarisine ait en iyi sonuçlar

Yöntem	Doğruluk (%)	Kesinlik (%)	Geri Getirme (%)	F ₁ Skor (%)
Görüntü Birleştirme	97,60	95,65	100	97,77

Çizelge 6.4.’te önerilen üçüncü yöntemden elde edilen sonuçlar yer almaktadır. Önerilen üçüncü yöntemde görüntüler oluşturulmadan önce tekil değer ayrışımı ile özdeğer matrisler elde edilmiş ve bu matrisler ile görüntüler oluşturulmuştur. Her bir dönüşüm yöntemi ile elde edilen verilerin oluşturulan ESA modeli ve kendine özgü parametreleri ile

eğitilmesinden elde edilen sonuçlar raporlanmıştır. Raporlanan sonuçlarda tekil değer ayrışımı yönteminin özellikle GAA ile uygulanmasının ESA mimarisi için çok fazla başarımlı göstermediğini, MGA ve TG ile uygulanmasından sonra elde edilen sonuçlarında bu çalışmada gerçekleştirilen diğer yöntemlere göre daha düşük olduğu gözlemlenmiştir. Bu sebeple tekil değer ayrışımı yöntemi ile görüntü birleştirme yöntemi olan son yöntem önerilmiş ve deneysel çalışması yapılmıştır.

Çizelge 6.4. Sensör verisi görüntü dönüşümü ve tekil değer ayrışımı yöntemi ile elde edilen yeni veri seti ile ESA mimarisine ait en iyi sonuçlar

Yöntem	Doğruluk (%)	Kesinlik (%)	Geri Getirme (%)	F ₁ Skor (%)
TG + TDA	92,30	95,23	90,90	93,01
MGA + TDA	81,46	85	77,27	80,95
GAA + TDA	60,62	65	59,09	61,90

Son olarak Çizelge 6.5.'te görüntü dönüşümü ve tekil değer ayrışımı yöntemleri ile elde edilen veri setinin görüntü birleştirme yöntemleri ile tek bir veri seti haline getirilmesi ve elde edilen bu veri setinin ESA modelinin eğitilmesine ait sonuçlar yer almaktadır.

Çizelge 6.5. Sensör verisi görüntü dönüşümü ve tekil değer ayrışımı yöntemi ve görüntü birleştirme teknikleri ile elde edilen yeni veri seti ile ESA mimarisine ait en iyi sonuçlar

Yöntem	Doğruluk (%)	Kesinlik (%)	Geri Getirme (%)	F ₁ Skor (%)
Görüntü Birleştirme + TDA	100,00	100,00	100,00	100,00

Bu tez kapsamında yapılan çalışmalarda üç farklı matematiksel dönüşüm yöntemi (GAA, MGA, TG) kullanılarak yenilikçi bir yaklaşım sunulmaktadır. Bu yaklaşım ile verinin temsil formatı değiştirilerek derin öğrenme algoritmalarının kullanılması sağlanmaktadır. İlk yöntemden elde edilen sonuçlar kıyaslandığında en iyi sonucu 98,55 doğruluk, 100,00 kesinlik, 97,29 geri getirme ve 98,62 F₁ skor ile TG yönteminden elde edilen veri setinin kullanıldığı ESA mimarisi ile alındığı gözlemlenmiştir. İkinci yöntemde ilk yönteme ek olarak görüntü birleştirmesi yapılmıştır. Bu yöntem ile elde edilen veri setinin kullanıldığı modelin eğitilmesi ile elde edilen sonuçlar 97,60 doğruluk, 95,65 kesinlik, 100,00 geri getirme ve 97,77 F₁ skor ile ilk yönteme yaklaşmış ancak daha yüksek performans gösterememiştir. Üçüncü yöntemde ilk iki yöntemden farklı olarak tekil değer ayrışması

eklenmiştir. Elde edilen 3 farklı yönteme ait veri setlerinin kullanıldığı ESA modellerinden elde edilen sonuçlardan 92,30 doğruluk, 95,23 kesinlik, 90,90 geri getirme ve 93,01 F1 skor ile bu yöntemin en yüksek performansını TG + TDA yöntemi vermektedir. Üçüncü yöntemde ilk iki yöntemden daha düşük bir performans elde edilmiştir. Tekil değer ayrışımı yöntemi ile GAA, MGA, TG yöntemlerinin ayrı ayrı uygulanmasından düşük başarı oranı elde edilmesinden dolayı görüntü birleşimi eklenmesi ile başarımın artması öngörülerek çalışma kapsamında gerçekleştirilen son yöntem önerilmiştir. Bu çalışma kapsamında önerilen son yöntemde tekil değer ayrıştırmasının eklenmesi ile oluşturulan 3 farklı veri seti görüntü birleştirmesi ile tek bir veri seti haline getirilmiştir. Bu veri seti için oluşturulan ESA mimarisinden elde edilen sonuçların 100,00 doğruluk, 100,00 kesinlik, 100,00 geri getirme ve 100,00 F₁ skor ile hem bu tez çalışmasında önerilen yöntemlerden elde edilen sonuçlardan hem de literatürde bulunan aynı veri seti ile gerçekleştirilmiş diğer yöntemlerden elde edilen sonuçlardan daha yüksek olduğu gözlemlenmiştir.

Sonar verisi ile daha önce literatürde denenmemiş olan görüntü dönüşümü yöntemleri ile sonar veri setinden görüntüler elde edilmesi ile oluşturulan yenilikçi bu yöntemin performansı farklı evrişimli sinir ağı mimarileri ile denenmiş ve test edilmiştir. Elde edilen sonuçlara bakıldığında görüntü dönüşümü yönteminin tekil değer ayrışımı ve birlikte görüntü birleşimi yöntemleri ile birlikte kullanıldığında uygun hiperparametre optimizasyonları ile çok daha başarılı sonuç verdiği gözlemlenmiştir.

4 farklı yöntem için oluşturulan 4 farklı veri seti için aşırı uyumun önüne geçecek ve aynı zamanda başarımı arttıracak hiper parametreler kullanılarak birbirinden farklı evrişimli sinir ağı modelleri oluşturulmuştur. Önerilen yenilikçi yöntemler, veri temsilinin değiştirilmesinden önce kullanılan makine öğrenme algoritmaları ve literatürde yapılan çalışmalar arasında elde edilen en yüksek performans ve başarımın bu tez çalışmasında önerilen son yenilikçi yöntem olduğu gözlemlenmektedir. Verinin temsilinin değiştirilmesi sırasında tekil değer ayrışımı yöntemi ile veriye ait en ilgi çekici özelliklerin ortaya çıkarıldığı öz değer matrisinin görüntüye dönüştürülmesi ve farklı yöntemlerden elde edilen özelliklerinin birleşimi ile özellik artırımının sağlanması ile bilinen en yüksek sonuç elde edilmiştir. Literatürde aynı veri seti ile yapılmış çalışmalarda yöntemler incelendiğinde yüksek başarımın elde edilmesi için boyut azaltma yaklaşımlarının kullanıldığı gözlemlenmektedir.

7. SONUÇ VE ÖNERİLER

Gelişen sistemler ile birlikte değişen dünyada, sonar sinyalleri gibi askeri ve sivil alanlarda oldukça değerli olan verilerin anlamlandırılması giderek daha büyük önem taşımaktadır. Sonar ile deniz tabanı haritalamasını yapılması, yerleştirilen mayın ve mayın benzeri nesnelerin tespiti ve sınıflandırılmasının yapılması sualtındaki değişken ortam şartları ve ortam kirliliği sebebi ile zorlaşmaktadır. Böyle durumlarda tespit edilen nesneden ya da çıkarılan deniz tabanı haritalamalarından emin olunması amacı ile insan gücüne ihtiyaç duyulmaktadır. Bu koşulları zor ve hayati tehlike taşıyan durumları ortaya çıkarmaktadır. Olası savaş dönemlerinde gemi çıkarmalarını yapabilmek ve limon güvenliğini sağlayabilmek, barış dönemlerinde ise yük gemileri, petrol arama sondaj gemileri ve benzeri su üstü ve sualtı araçlarının güvenliğini sağlayabilmek için sualtındaki bilinmezliği ortadan kaldırmak çok önemlidir. Sualtı ortamının değişkenliği ve zorlu koşulları düşünülecek olduğunda verilerin elde edilmesinin zorluğu ve her elde edilen verinin değeri anlaşılmaktadır. Balık sürülerinin tespitinden, denizlerin güvenliğine kadar birçok farklı alanda yararlı olacak verilerin gizliliği ülkeler için büyük önem taşımaktadır. Bu sebeple, bu alanda açık veri setlerinin bulunması çok zor olmaktadır. Literatürde yapılan taramalar sonucunda gerek sonar sinyal gerekse sonar görüntü veri seti bulmanın zorluklarından bahsedilmektedir [57][58]. Toplanması ve anlamlandırılması zor olan bu veri seti ile yapılmış bu tez çalışması kapsamında elde edilen sonuçlar, gerçekleştirilen deneysel çalışmanın gelecek çalışmalara örnek olabileceğini göstermektedir. Çalışmada literatürde bilinen en iyi sonuçlar elde edilmiştir.

Bu tez çalışmasında; 60 farklı frekans bandından alınan dönüşlere ait sonar sinyal verilerinin derin öğrenme algoritmaları ile kullanılabilmesi için verinin temsili değiştirildiği yeni bir yöntem önerilmiştir. Gramian Açısız Alan, Markov Geçiş Alanı ve Tekrarlanma Grafiği olmak üzere toplamda üç farklı matematiksel dönüşüm yöntemi kullanılarak çalışmalar yapılmıştır. Çalışma boyunca önerilen yenilikçi yöntem toplam 4 farklı model ile denenmiş ve test edilmiştir. Önerilen yöntemler, aynı veri seti ile denenilen klasik makine öğrenme algoritmaları sonuçları ve literatürde bu veri seti ile gerçekleştirilen çalışmalar ile karşılaştırılmıştır. Önerilen ilk modelde dönüşüm yöntemlerinden alınan görüntülerin her biri ayrı ayrı derin öğrenme algoritmasına verilerek sonuçlar alınmıştır ve bu sonuçlar arasında tekrarlanma grafiği yöntemi %98.55 doğruluk ile oldukça yüksek

performans göstermiştir. Sayma tabanlı olasılıksal bir dönüşüm yöntemi olan tekrarlanma grafiği yönteminin sonar veri seti ile diğer dönüşüm yöntemlerine göre daha iyi sonuç verdiği gözlemlenmiştir. Önerilen ikinci modelde, daha fazla özellik elde etmek için görüntüler birleştirilmiş ve yeni bir veri seti oluşturularak derin öğrenme algoritmasına verilmiştir. Bu yöntem sonucunda %97.60 doğruluk oranı ile taranan literatür çalışmaları ve çalışmada kullanılan klasik makine öğrenme algoritmalarına göre başarılı bir sonuç elde edilmiştir. Ancak bu sonuç tek başına tekrarlanma grafiğinden elde edilen sonuçtan çok az da olsa düşüktür. Üçüncü modelde verinin temsilinin değiştirilmesi sırasında oluşan matrise görüntüye dönüştürülmeden önceki en dikkat çekici özelliklerinin çıkarılması için Tekil Değer Ayrışımı yöntemi uygulanmıştır. Bu yöntem ile görüntü oluşturulmadan önce matris öz değerlerine ve öz vektörlerine ayrılmıştır. Evrişimli sinir ağı mimarisinin seyrek veri ile daha verimli çalışması ve sınıflandırma başarımının en dikkat çekici özellikler ile performansının artırılması bu yöntemin kullanılmasındaki temel sebep olmuştur. Elde edilen yeni veri setleri ayrı ayrı derin öğrenme algoritmalarına verilmiştir. Bu modelde 92,30 ile ilk iki yöntemden biraz daha düşük bir sonuç elde edilmiştir. Önerilen üçüncü yöntemin başarısının artırılması için, önerilen 2. yönteme benzer şekilde görüntü birleştirme teknikleri uygulanarak tek bir veri seti oluşturulmuş ve derin öğrenme algoritmasına verilmiştir. %100 oranında doğruluk, kesinlik, geri getirme ve F₁-skor elde edilmiştir. Literatürde bulunan aynı veri seti ile yapılan incelediğimiz çalışmalar arasında tespit edilen en yüksek başarı oranı 96,25'tir [7]. Bunu takip eden en yüksek başarı oranı olan çalışma 95,19 doğruluk oranı elde etmiştir [11]. Uygulanan bu son yöntemden elde edilen sonuçlar, literatürde incelenen aynı veri seti ile yapılan çalışmalardan, bu çalışmada denenen klasik makine öğrenme algoritmalarından elde edilen sonuçlardan ve önerilen yenilikçi yöntem ile oluşturulan modellerden elde sonuçların hepsinden daha yüksek doğruluk oranı sağlayarak önerilen yaklaşımın üstünlüğünü doğrulamıştır. GAA, MGA ve TG dönüşümleri ve TDA yöntemi ile kullanılması ile önerilen yöntemin klasik yöntemlerden daha etkin ve daha başarılı öznetelik çıkarıcı olduğu görülmektedir.

Sonar veri seti yapısı gereği çok zor bulunan ve dolayısı ile üzerine sınırlı sayıda çalışma yapılmış bir veri seti olarak bilinmektedir. Sonar veri setinin boyutunun az olması ve açık veri seti bulunmaması çalışmalarda karşılaşılan en büyük zorluklardan biri olmuştur. Bu sebeple bu veri seti ile kullanılacak evrişimli sinir ağı mimarisi aşırı uyumun önüne geçilmesi için karmaşıklığından uzak tutulmuştur.

Gerçekleştirilen literatür taramasında, verinin temsilinin değiştirildiği bir çalışmaya sonar veri seti özelinde rastlanmamıştır. Literatürde klasik makine öğrenmesi yöntemi ve boyut azaltma yaklaşımının kullanıldığı yöntemler ile başarılı sonuçlar alındığı gözlemlenmiştir. Az sayıda bulunan sonar sinyallerinden oluşan veri setinin temsilinin değiştirilerek derin öğrenme algoritmaları ile kullanılmasının sağlanması, elde edilen sonuçlar da göz önüne alındığında başarılı bir yenilikçi yaklaşım olarak değerlendirilmektedir. Diğer birçok ülke gibi kendi ülkemiz için de stratejik öneme sahip olan sonar veri setlerinin toplanması ve toplanan verilerin önerilen yöntem ve bu yöntemin geliştirilmesi ile ortaya çıkacak olan yeni yöntemler ile sınıflandırılıp anlamlandırılması ülkemize birçok alanda maddi ve manevi kazançlar sağlayacaktır.

İlerleyen çalışmalarda farklı derin öğrenme mimarileri ile dönüşüm yöntemlerinin performansları ve dönüşüm yöntemleri ile tekil değer ayrışımı yönteminin öznelilik çıkarma kapasitesi araştırılacaktır. Geliştirilebilecek olan sonar sinyalleri üreten simülatörler ile veri sayısının arttırılması yapılacak çalışmaların daha güvenli ve daha yüksek performanslı olmasına imkân tanıyacaktır. Gerçekleştirilen çalışma ve sonrasında bu çalışmanın ilerletilmesi ve genişletilmesi ile elde edilecek ürün ve alınacak sonuçlar ulusal alanda güvenliğimizi ve gelişimimizi destekleyecektir. Çalışmadan elde edilen sonuçlar, bu alana yapılacak teknolojik yatırım ile sadece mayın ve benzeri objelerin tespiti ile askeri olarak gelişimin değil, birçok sivil alanda da gelişimin olacağının bir göstergesi olmaktadır.

KAYNAKLAR

1. Waite, A. D. (2002). *Sonar Practising Engineers* (Second edition). West Sussex: Wiley.
2. Jing, L. (2018). The principle of side scan sonar and its application in the detection of suspended submarine pipeline treatment. *Materials Science and Engineering*, 439.
3. Verleysen, M., and François, D. (2005). The Curse of Dimensionality in Data Mining and Time Series Prediction. *Lecture Notes in Computer Science*, 3512(06), 758–770.
4. Gorman, R.P., and Sejnowski, T.J. (1988). Analysis of Hidden Units in a Layered Network Trained to Classify Sonar Targets. *Neural Networks*, 1(1), 75–89.
5. Erkmén B., and Yıldırım T. (2008). Improving classification performance of sonar targets by applying general regression neural network with PCA. *Expert Systems with Applications*, 35(1-2), 472–475.
6. Pamaja V., Rajendran V., and Vijayalakshmi P. (2020). Study on metal mine detection from underwater sonar images using data mining and machine learning techniques. *Journal of Ambient Intelligence and Humanized Computing*, 11(4), 5083–5092.
7. Fong, S., Deb, S., and Wong, R. et al. (2014). Underwater Sonar Signals Recognition by Incremental Data Stream Mining with Conflict Analysis. *International Journal of Distributed Sensor Networks*. 10(5), 1-12.
8. Hossin M., Mahudin F., Din, I., and Mat, A.R. (2017). Analysis of Nine Instance-Based Genetic Algorithm Classifiers Using Small Datasets. *Journal of Telecommunication, Electronic and Computer Engineering*, 9, 3–11.
9. Novakovic, J. (2009). *Using Information Gain Attribute Evaluation to Classify Sonar Targets*. 17th Telecommunications forum, 1351-1354.
10. Hong, X., Zhang, J., and Guan, S.U. et al. (2017). *Incremental Maximum Gaussian Mixture Partition For Classification*, Paper presented at the 2nd Joint International Information Technology, Mechanical and Electronic Engineering Conference, Chongqing, China.
11. Bakbak, P.O., and Peker, M. (2020). Classification of sonar echo signals in their reduced sparse forms using complex-valued wavelet neural network. *Neural Computing and Applications*, 32(1).
12. Singh, H., and Hooda, N. (2019) Prediction of Underwater Surface Target through SONAR: A Case Study of Machine Learning. *Microservices in Big Data Analytics*, 111-117.
13. Zhu, H., Bi, N., Tan, J., and Fan, D. (2018). An Embedded Method for Feature Selection Using Kernel Parameter Decent Support Vector Machine. *Pattern Recognition and Computer Vision*, 351-362.
14. Ghosh, R. (2018). Sonar Target Classification Problem: Machine Learning Models. *International Journal of Science and Research*, 9(1), 247-248.

15. Sun, N. (2004). *Neural Network in Classifying Sonar Targets: Mines and Rocks*. Unpublished Master's Thesis, Research School of Computer Science, Australian National University, Australia.
16. Shang, T., Xia, X., and Zheng, J. (2018). MIME-KNN: *Improve KNN Classifier Performance Include Classification Accuracy and Time Consumption*. International Conference on Computer Science and Software Engineering, 129-139.
17. Sartoli, S., Wei, Y., and Hampton, S. (2020). *Malware Classification using Recurrence Plots and Deep Neural Network*. Paper presented at the 19th IEEE International Conference on Machine Learning and Applications, Miami, Florida.
18. Thanaraj, P., Parvathavarthini, B., Tanik, U., Rajinikanth, V., Kadry, S., and Kamalanand, K. (2020). Implementation of Deep Neural Networks to Classify EEG Signals using Gramian Angular Summation Field for Epilepsy Diagnosis. *Computer Vision and Pattern Recognition*, 1-9.
19. Akpınar, H. (2014). *DATA – Veri Madenciliği Analizi*. (Birinci Baskı). Türkiye: Papatya Bilim Yayınevi.
20. Raschka, S., and Mirjalili, V. (2017). *Python Machine Learning* (Second edition). Birleşik Krallık: Packt.
21. Noble, W. (2006). What is a support vector machine? *Nature Biotechnology*, 24, 1565–1567.
22. Budak, H. (2018). Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(10), 21-31.
23. Xanthopoulos, P., Pardalos, P.M., and Trafalis, T.B. (2013). *Robust Data Mining*. (Second edition). USA: Springer Yayınevi, 27-33.
24. Park, C. H., and Park, H. (2008). A comparison of generalized linear discriminant analysis algorithms. *Pattern Recognition*, 41(3), 1083–1097.
25. Hosmer, D. W., and Lemeshow, S. (2000) *Applied Logistic Regression*, (Second edition). USA: Wiley, 91-135.
26. Grimm, L. G., and Yarnold, P. R. (1995). *Reading and understanding multivariate statistics*, (First edition). USA: APA, 217–244.
27. Bustamante, C., Garrido, L., and Soto, R. (2006) Comparing Fuzzy Naive Bayes and Gaussian Naive Bayes for Decision Making in RoboCup 3D. *Advances in Artificial Intelligence*. 4293, 237-247.
28. Raizada, R.D.S., Lee, Y., and Lee, S. (2013) Smoothness without Smoothing: Why Gaussian Naive Bayes Is Not Naive for Multi-Subject Searchlight Studies. *PLoS ONE* 8(7).
29. Tangirala, S. (2020). Evaluating the Impact of GINI Index and Information Gain on Classification using Decision Tree Classifier Algorithm. *International Journal of Advanced Computer Science and Applications*, 11(2), 612-619.

30. Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
31. Mitchell, T. (1997). *Machine Learning*, (First edition). ABD: McGraw Hill.
32. Wang, Z., and Oates, T. (2015). *Imaging Time-Series to Improve Classification and Imputation*, Paper presented at the Proceedings of the 24. International Joint Conference on Artificial Intelligence, Buenos Aires, Argentina.
33. Wang, Z., and Oates, T., et al. (2015). Spatially Encoding Temporal Correlations to Classify Temporal Data Using Convolutional Neural Networks. *Journal of Computer and Systems Sciences*, 1-33.
34. Eckmann, J.P., Kamphorst, S.O., and Ruelle, D. (1987) Recurrence Plots of Dynamical Systems. *Euro- Physics Letters*, 4(9), 973–977.
35. Tang, Z., Zeng, X., Guo, Z., and Song, M., (2020). Malware Traffic Classification Based on Recurrence Quantification Analysis. *International Journal of Network Security*, 22, 449-459.
36. Jiang, Z.R., and Yen, C.T. (2020). *Markov Transition Field and Convolutional Long Short-Term Memory Neural Network for Manufacturing Quality Prediction*, Paper presented at the 2020 IEEE International Conference on Consumer Electronics., In Phu Quoc Island, Vietnam.
37. Garcia, G., Michau, G., Ducoffe, M., Sen Gupta, J., and Fink, O. (2020). Time Series to Images: Monitoring the Condition of Industrial Assets with Deep Learning Image Processing Algorithms. *Journal of Risk and Reliability*, 1-11.
38. Sadek, R.A. (2012). SVD Based Image Processing Applications: State of The Art, Contributions and Research Challenges. *International Journal of Advanced Computer Science and Applications*, 3(7), 26-34.
39. Xue, J., Li, J., and Gong. Y. (2013). Restructuring of Deep Neural Network Acoustic Models with Singular Value Decomposition. *INTERSPEECH*, 2365-2369.
40. Sun, Y., Xue, B., Zhang, M., and Yen, G.G. (2020). Completely Automated CNN Architecture Design Based on Blocks. *IEEE Transactions on Neural Networks and Learning Systems*, 31(4), 1242-1254.
41. Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. (First edition). ABD: MIT Press, 325-329.
42. Soon, F.C., Khaw, H.Y., Chuah, J.H., and Kanesan, J. (2018). Hyper-parameters optimisation of deep CNN architecture for vehicle logo recognition. *IET Intelligent Transport Systems*, 12(8), 939-946.
43. Qi, X., Wang, T., and Liu, J. (2017). *Comparison of Support Vector Machine and Softmax Classifiers in Computer Vision*. Paper presented at the 2017 Second International Conference on Mechanical, Control and Computer Engineering, Harbin, China, 151-155.

44. Ide, H., and Kurita, T. (2017). *Improvement of learning for CNN with ReLU activation by sparse regularization*. International Joint Conference on Neural Networks (IJCNN), 2684-2691.
45. Banerjee, C., Mukherjee, T., and Pasiliao, E. (2020). *The Multi-phase ReLU Activation Function Annals of Statistics*, Paper presented at the 2020 ACM Southeast Conference, Florida, United States, 239-242.
46. Nwankpa, C., Ijomah, W., Gachagan, A., and Marshall, S. (2020). *Activation Functions: Comparison of trends in Practice and Research for Deep Learning*. Paper presented at the 2nd International Conference on Computational Sciences and Technologies, Jamshoro, Pakistan, 124-133.
47. Jamel, T., Mohammed, B. (2012). *Implementation of a Sigmoid Activation Function for Neural Network Using FPGA*. Paper presented at the 13th Scientific Conference of Al-Ma'moon University College, Baghdad, Iraq.
48. Taqi, A. M., Awad, A., Al-Azzo, F., and Milanova, M. (2018). *The Impact of Multi-Optimizers and Data Augmentation on TensorFlow Convolutional Neural Network Performance*. Paper presented at the IEEE Conference on Multimedia Information Processing and Retrieval, Guangdong, China, 140-145.
49. Ruby, A.U., Theerthagiri, P., Jacob, I.J., and Vamsidhar, Y. (2020). Binary cross entropy with deep learning technique for Image classification. *International Journal of Advanced Trends in Computer Science and Engineering*, 9(4), 5393-5397.
50. Alpaydın, E. (2011). *Introduction to Machine Learning*. (Fourth edition). İstanbul: Boğaziçi Üniversitesi Yayınevi.
51. Murugan, P., and Durairaj, S. (2017). *Regularization and Optimization strategies in Deep Convolutional Neural Network*. ArXiv, abs/1712.04711, 1-15.
52. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15(1), 1929-1958.
53. Siddharth, K., (2017). On weight initialization in deep neural networks. *ArXiv*, arXiv:1704.08863.
54. Glorot, X., and Bengio, Y. (2010). *Understanding the difficulty of training deep feedforward neural network*. Paper presented at the 13th International Conference on Artificial Intelligence and Statistics, Sardinia, Italy, 249-256.
55. Sokolova, M., Japkowicz, N., and Szpakowicz, S. (2006). Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation. *AI 2006: Advances in Artificial Intelligence Lecture Notes in Computer Science*, 4304, 1015-1021.
56. Goutte, C., and Gaussier, E. (2005). A Probabilistic Interpretation of Precision, Recall and F-Score, with Implication for Evaluation. *Lecture Notes in Computer Science*. 3408. 345-359.

57. Huo, G., Wu, Z., and Li, J. (2020). Underwater Object Classification in Sidescan Sonar Images Using Deep Transfer Learning and Semisynthetic Training Data. *IEEE Access*, 8, 47407-47418.
58. Dura, E., Zhang, Y., Liao, X., Dobeck, G., and Carin, L. (2005). Active Learning for Detection of Mine-Like Objects in Side-Scan Sonar Imagery. *Oceanic Engineering, IEEE Journal*, 30, 360 - 371.



GAZİ GELECEKTİR..