



## Time series - image transformation-based new approaches in detecting underwater objects with machine learning methods

Mustafa Umut Demirezen<sup>1\*</sup>, Aybüke Civrizoğlu Buz<sup>2</sup>, Uraz Yavanoğlu<sup>3</sup>

<sup>1</sup>ROKETSAN A.Ş., STGD Artificial Intelligence and Technology Management Unit Ankara, 06852, Turkey

<sup>2</sup>HAVELSAN A.Ş., Command Control and Defense Technologies Technology Development Group Ankara, 06510, Turkey

<sup>3</sup>Gazi University, Faculty of Engineering, Computer Engineering Department, Ankara, 06570, Turkey

### Highlights:

- Proposing a new method for using time series data with CNN based deep learning architectures
- The new data representation obtained by using three different mathematical transformation
- The proposed approach shows the highest performance known in the literature for the sonar data set

### Graphical/Tabular Abstract

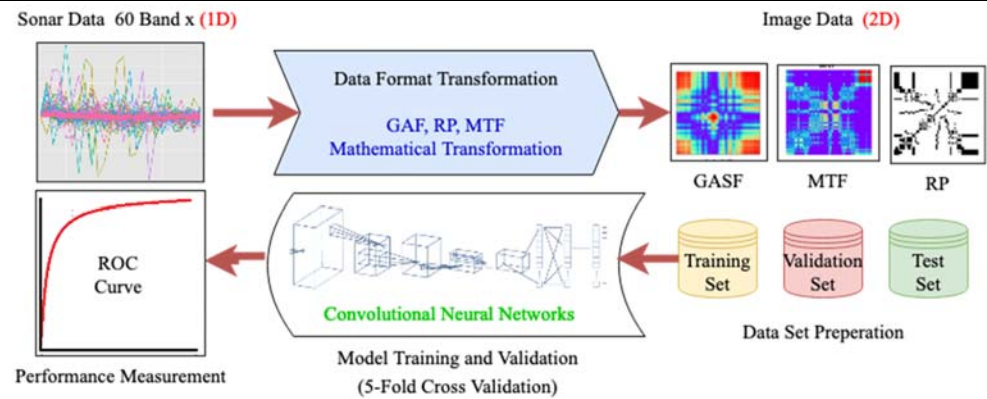


Figure A. Proposed Novel Method for Sonar Data Classification

### Keywords:

- Markov Transition Field,
- Gramian Angular Field,
- Repetition Plots,
- Sonar,
- Deep Learning

### Article Info:

Research Article  
Received: 16.11.2020  
Accepted: 06.02.2021

### DOI:

10.17341/gazimmfd.826453

### Correspondence:

Author: Mustafa Umut Demirezen  
e-mail: umut@demirezen.tech  
phone: +90 532 609 0985

**Purpose:** In this study, using three different mathematical transformations as an innovative approach, the numerical representation of sonar signal data in image format is proposed and the performance of a deep learning architecture is compared with classical machine learning and statistical pattern recognition methods in this binary classification problem.

### Theory and Methods:

The proposed method is basically based on converting the time series data into three channel (RGB) or single channel (gray) lossless image format. When the time series data is transformed into image representation, the classification problem can be solved by using machine learning methods on these images. The visual transformation of time series data was carried out using three different methods called Gramian Angular Filed (GAF), Markov Transition Field (MTF), and Recurrence Plot (RP). A custom CNN architecture was built and trained with cross validation method, and classification performance was tested. Also, classical machine learning algorithms (Support Vector Machine, LDA, K-Nearest Neighborhood, Logistic Regression, Gaussian Naïve Bayes, Random Forest, Decision Tree) are also tested without feature engineering by using the same sonar dataset.

### Results:

The success rates obtained with the CNN model trained after RP, MTF and GADF transformations were 98.55%, 97.10% and 95.65%, respectively. the most successful results were obtained with 98.55% accuracy for CNN trained on images obtained by the repetition plot method, and following this result, 97.10% and 95.65% accuracy rates were obtained with MTF and GADF methods, respectively. Classical machine learning and statistical pattern recognition methods have been applied to the data set containing sonar signals and it was observed that results varied between 92.30% and 67.30% among all algorithms tested, and the most successful results were obtained with SVM.

### Conclusion:

Using accuracy, retrieval, precision and F1 criterion metrics and sonar data set, which is a well-known and very difficult data set in the literature, it is compared with classical machine learning algorithms and the superiority of the proposed approach is verified. In addition, by examining the previous studies in the literature on the sonar data set used in this study, it was determined that the highest known scores were obtained with the proposed systematic approach.



## Sualtı objelerinin makine öğrenmesi yöntemleri ile tespitinde zaman serisi-görüntü dönüşümü tabanlı yeni yaklaşımlar

Mustafa Umut Demirezen<sup>1\*</sup>, Aybüke Civrizoğlu Buz<sup>2</sup>, Uraz Yavanoğlu<sup>3</sup>

<sup>1</sup>ROKETSAN A.Ş., STGD Yapay Zekâ ve Teknoloji Yönetimi Birimi Ankara, 06852, Türkiye

<sup>2</sup>HAVELSAN A.Ş., Komuta Kontrol ve Savunma Teknolojileri Teknoloji Geliştirme Grubu Ankara, 06510, Türkiye

<sup>3</sup>Gazi Üniversitesi MF Bilgisayar Mühendisliği Bölümü, Ankara, 06570, Türkiye

### Ö N E Ç İ K A N L A R

- Zaman serisi-görüntü dönüşümü yöntemleri
- Önerilen veri temsiline, görüntü işleme tabanlı derin öğrenme algoritmaları ile kullanılması
- Literatürdeki diğer yöntemler ile karşılaştırıldığında aynı veri seti için bilinen en yüksek başarıma ulaşılması

### Makale Bilgileri

Araştırma Makalesi  
Geliş: 16.11.2020  
Kabul: 06.02.2021

### DOI:

10.17341/gazimmfd.826453

### Anahtar Kelimeler:

Markov dönüşüm alanı,  
Gramian açılal alan,  
tekrarlama grafiği,  
sonar,  
derin öğrenme

### ÖZ

Ses dalgalarını kullanarak cismin boyut, uzaklık, yön ve diğer özelliklerinin tespit edilmesi için kullanılan sonar; denizaltı maden, petrol aramalarında, denizaltı haritalamasında, balık sürülerinin takibinde ve mayın tespitlerinde yaygın olarak kullanılmaktadır. Sonar sinyallerinin tanımlanması ve sınıflandırılması için kullanılması gereken öznelik çıkarımı, seçimi, uygun algoritmaların seçilmesi ve hiperparametrelerinin en iyilemesi çalışmaları, üzerinde uzun yıllardan beri çalışılan bilimsel problemlerdir. Bu çalışmada, yenilikçi bir yaklaşımla üç farklı matematiksel dönüşüm kullanılarak verinin farklı bir formatta sayısal temsili önerilmekte ve derin öğrenme yöntemlerinin bu problem özelinde başarımlarının klasik makine öğrenmesi ve istatistiksel örüntü tanıma yöntemleri ile karşılaştırılması yapılmaktadır. Markov Dönüşüm Alanı, Gramian Açılal Alanı ve Tekrarlanma Grafiği matematiksel dönüşümleri verinin zaman serisi türünden görüntü formatında ifade edilebilmesi için kullanılmıştır. Elde edilen dönüştürülmüş verilerin kullanılmasıyla, derin öğrenme algoritmalarının eğitilmesi sağlanarak, üretilen modellerin başarımları ve klasik algoritmalar ile elde edilen sonuçlar, metrikler yardımıyla karşılaştırılmıştır. Önerilen zaman serisi verisinin görüntüye dönüştürülmesi yaklaşımlarının, problem çözümünde öznelik çıkarma gereksinimini ortadan kaldırdığı ve bugüne kadar literatürde tespit edilen en iyi sonuçları verdiği belirlenmiştir. Önerilen yeni yaklaşımın, sadece zaman serisi tabanlı sınıflandırma problemleri için değil, farklı araştırma alanlarında da uygulanabileceği ve verinin temsili amacıyla, önerilen matematiksel dönüşümler ile makine öğrenmesi algoritmalarının başarımlarının artırılması için önemli katkılar sağlayacağı değerlendirilmektedir.

## Time series - image transformation-based new approaches in detecting underwater objects with machine learning methods

### H I G H L I G H T S

- Proposal of Time series - image transformation methods
- Using the proposed data representation with image processing-based deep learning algorithms
- Achieving the highest known success for the same data set compared to other methods in the literature

### Article Info

Research Article  
Received: 16.11.2020  
Accepted: 06.02.2021

### DOI:

10.17341/gazimmfd.826453

### Keywords:

Markov transition field,  
Gramian angular field,  
repetition plots,  
sonar,  
deep learning

### ABSTRACT

Sonar used to determine the size, distance, direction and other features of an object using sound waves; It is widely used in underwater mining and oil exploration, submarine mapping, tracking fish shoals and mine detection. Feature extraction, selection, selection of appropriate algorithms and optimization of hyperparameters that should be used for the identification and classification of sonar signals are scientific problems that have been studied for many years. In this study, using three different mathematical transformations as an innovative approach, numerical representation of data in a different format is proposed and the performance of deep learning methods in this particular problem is compared with classical machine learning and statistical pattern recognition algorithms. Mathematical transformations of Markov Transform Field, Gramian Angular Field and Repetition Plot are used to express the data in image format from time series type. By using the transformed data obtained, deep learning algorithms were trained and the performance of the produced models and the results obtained with classical algorithms were compared with the help of metrics. It has been determined that the proposed time series data to image transformation approaches eliminate the need for feature extraction in problem solving and give the best results determined in the literature so far. It is considered that the proposed new approach can be applied not only to time series based classification problems, but also in different research areas, and will provide significant contributions to increase the performance of machine learning algorithms with the proposed mathematical transformations for the representation of data.

\*Sorumlu Yazar / Yazarlar / Corresponding Author / Authors: \*umut@demirezen.tech, acivrizoğlu@havelsan.com.tr, uraz@gazi.edu.tr /  
Tel: +90 532 609 0985

## 1. GİRİŞ (INTRODUCTION)

Özellikle son yıllarda sualtı dünyasının keşfinde yaşanan gelişmeler, sualtındaki nesnelerin ve sualtı hedeflerinin tespiti ve sınıflandırılması, sivil ve askeri amaçlı çok fazla uygulamada önemli bir yere sahip olmaktadır. Sualtı dünyasının keşfi için kullanılan sonar (Sound Navigation and Ranging), ses dalgalarını kullanarak cisimlerin boyutu, uzaklığı ve yapıları hakkında bilgi sahibi olunabilmesi için kullanılan bir sistemdir [1]. Sonar sistemleri ilk önceleri deniz harpleri için geliştirilmiş olsa da günümüzde petrol ve maden aramaları, deniz tabanı haritalamaları, balık sürülerinin tespiti, dalga ve akıntıların ölçülmesi, batık gemilerin, boğulmuş ve deniz dibine batmış insanların, uçak gibi enkazların tespiti ve su altı arama kurtarma maksadıyla birçok önemli alanda kullanılmaktadırlar [2]. Günümüzde sonar sistemleri, sualtı hedef ve mayın tespiti konusunda, savunma sanayi alanında önemli yer tutmaktadır [3]. Sadece savaş dönemlerinde değil özellikle barış dönemlerinde de kıyı emniyetini korumak, gemi çıkarmalarını ve liman kontrollerini sağlıklı bir şekilde yürütmek gibi konularda sıklıkla kullanılan sonar sistemleri, teknolojinin gelişmesiyle birlikte yeni alanlarda, daha da gelişmiş imkânlar sunmaya başlamıştır [4]. Teknolojinin gelişmesiyle birlikte sonar cihazlarından alınan sinyallerin ve görüntülerin hem kalitesi hem de barındırdığı özellikleri artmıştır. Son yıllarda gerek görüntü ile gerekse sinyal ile yapılan çalışmalarda özellikle mayın ve benzeri nesneler için veri setleri ve kaynakların az olması, bu alandaki araştırmaları zorlaştırmakta olsa da literatürde yayınlanmış makine öğrenmesi tabanlı ve istatistiksel analiz yöntemlerine dayanan sınırlı sayıda çalışma bulunmaktadır [4-7].

Sualtı mayın çeşitliliğinin fazla olması, kaya, enkaz, kablo gibi diğer nesnelerin şekil ve yapı olarak mayınlara benzerliği, sinyal yansımaları, sinyal üzerine eklenebilen bozucu etki üreten gürültüler gibi nedenlerden ötürü, mayın objelerinin yapay zekâ algoritmaları ile tespiti zorlaşmaktadır. Klasik makine öğrenmesi algoritmaları temel olarak öznitelik çıkarımına dayanmaktadır. Problem özelinde geliştirilen bu özniteliklerin elde edilmesi alan uzmanlığı ile yapılabilmektedir. Ayrıca üretilen özniteliklerin arasından en önemlilerinin seçilmesi makine öğrenimi algoritmalarının eğitilmesinde ve elde edilen sonuçların geliştirilmesinde ve iyileştirilmesinde önemli bir rol oynar. Fazla sayıda öznitelik üretilmesi, "*boyutun laneti*" [8] olarak adlandırılan, öznitelik sayısının artması sonucunda, algoritma için ihtiyaç duyulacak eğitim verisi sayısının üssel şekilde astronomik ölçüde artması problemlerine neden olmaktadır. Az sayıda eğitim verisi ve fazla sayıda öznitelik kullanımı algoritmanın veriyi ezberlemesine neden olmaktadır (overfitting). Bu gibi durumlar ortaya çıktığında, makine öğrenmesi algoritmaları, genelleştirme kabiliyetlerini kaybettikleri için, sınıflandırma ya da regresyon problemlerinde başarılı sonuçlar elde edilememektedir. Klasik algoritmalar yerine öznitelik çıkarımı ve seçimi işlemlerinin otomatik olarak yapılabildiği derin öğrenme yöntemleri bu hususta daha fazla avantaj sağlıyor olsa da başarılı sonuçlar alabilmek için daha fazla

sayıda veriye ihtiyaç duymaktadır. Bu araştırmada, silindirik mayınlar ile bunlara şekil ve boyut olarak çok benzeyen silindirik kayalar üzerinden alınan ölçümlerin bulunduğu bir veri setinin [9] kullanılmasıyla, sonar verisinin farklı türlerde sayısal temsili için üç farklı matematiksel dönüşüm metodu önerilmektedir. Bu yenilikçi çözüm kapsamında, önerilen matematiksel dönüşüm metotları ile, bir boyutlu zaman serisi verisinin, iki boyutlu ve tek/çok kanallı resim formatına dönüştürülmesi sağlanmıştır. Önerilen dönüşüm metotları kullanıldıktan sonra orijinal verinin yeni bir türde sayısal temsiline oluşturulmasıyla yöntem, ikili sınıflandırma problemi olan kaya ve mayınların ayrıştırılması probleminde kullanılmış ve klasik makine öğrenmesi algoritmaları ile derin öğrenme algoritmalarının başarımları karşılaştırılmıştır. Ayrıca, aynı veri seti üzerinde gerçekleştirilmiş literatürdeki diğer çalışmaların kullandığı makine öğrenmesi ve istatistiksel örüntü tanıma algoritmalarının başarımları, önerilen yenilikçi yöntemin performansı ile mukayese edilmiştir. Verinin sayısal temsiline değiştirilmesi ile evrişimli sinir ağları (ESA) tabanlı derin öğrenme mimarisinin kullanılabilmesi sağlanmış ve nihayetinde sınırlı sayıda veri barındıran bu veri seti ile bugüne kadar literatürde rapor edilen en başarılı sonuçların elde edildiği gözlemlenmiştir.

## 2. LİTERATÜR ÖZETİ (LITERATURE REVIEW)

Okyanusta bulunan mayınların deniz yaşamındaki büyük gemilerin ve diğer canlıların güvenliği için büyük tehdit oluşturduğundan bahsedilen çalışmada [10] birçok faktör nedeni ile su altı nesnelere göre sonar görüntülerinin tespiti ve sınıflandırılmasının karmaşık bir konu olduğundan bahsedilmiştir. Hatta zamanla metal mayınların pasla kaplanacağından ötürü sadece görüntü işleme ile tanımlanamayacağını ve bu sebeple görüntü işleme algoritması ile birlikte yardımcı bir sınıflandırma algoritmasının kullanılması gerektiğinden bahsedilmiştir. Yapılan bu çalışmada temel olarak 3 farklı sınıflandırma algoritması karşılaştırılmıştır. Bu algoritmalar Gradyan artırma algoritması, Karar ağacı algoritması, K-En yakın komşu algoritmasıdır. Çalışmada kullanılan 208 adet veriye sahip olan veri seti %80 eğitim, %20 test verisi olarak bölünmüştür. Veriler tüm özellik seti ve en az yanlış negatif orana sahip özelliklerin seçildiği, seçilmiş özellik seti olmak üzere iki ayrı şekilde incelenmiştir. Bu çalışmanın sonuçlarına göre tüm özellik seti olarak bakıldığında gradyan artırma algoritması ile %90 doğruluk sağlanırken, K-En yakın komşu algoritması ile bu oran %80, karar ağacı algoritması ile %78 olarak elde edilmiştir. Seçili özellik setinin olduğu veriler ile çalışıldığında ise gradyan artırma algoritması %86, K-En yakın komşu algoritması %85, karar ağacı algoritması ise %64 oranında doğruluk sağlamıştır. Çalışmada elde edilen sonuçlara göre en iyi sonucu veren algoritmanın gradyan artırma algoritması olduğu belirtilmektedir.

Aynı veri seti ile yapılmış diğer çalışmada [11] aktif sonar kullanılarak sığ sulardaki denizaltı mayınlarının uzaktan

tespitinin, önemli limanların ve maliyet hattı alanlarının güvenliğini sağlamak için çok önemli bir konu olduğundan bahsedilmektedir. Su altı sinyallerinin sonar sinyalleri temelinde otomatik olarak tanımlanmasının ve sınıflandırılmasının okyanus ortamının karmaşıklığından dolayı zor bir problem olması nedeniyle, uzman insanlar tarafından yapılmasının mümkün olamadığı ağır bir iş yüküne neden olmaktadır. Bu makalede, genel regresyon sinir ağı (GRNN) sınıflandırma performansını iyileştirmek için bir özellik çıkarma yöntemi olan temel bileşen analizi (PCA) ile birlikte kullanılmıştır. Çalışmada veriler %50 eğitim %50 test olarak rastgele bölünmüştür. Hiçbir özellik çıkarma yöntemi kullanılmadan sadece GRNN modeli ile elde edilen başarı oranı %91,34 olurken PCA eklenerek eğitilmiş modelde elde edilen başarı oranı %93,26 olarak hesaplanmıştır. GRNN algoritmasının temel bileşen analizi kullanılarak elde edilen verilerle eğitildiğinde düşük veri sayısına rağmen gözle görülür şekilde daha iyi sonuçlar verdiği görülmüştür.

Karmaşık değerli dalgacık sinir ağı (CVWANN yöntemi kullanılan bir çalışmada [12] daha yüksek bir doğruluk derecesi ile azaltılmış aralıklı formlarını kullanarak sinyalleri sınıflandırmak için yeni bir yöntem belirlenmesi amaçlanmıştır. Bu çalışmada sonar sinyallerinin karmaşık azaltılmış formları için CVWANN modeli kullanılmıştır. Sınıflandırma işlemi başlamadan önce girdi sayısı 1/3'e indirilmiştir. Azaltılmış formdan elde edilen karmaşık değerli aralıklı katsayılar CVWANN tarafından sınıflandırılmıştır. Veriler incelendiğinde sinyallerin N/3 kısmının sıfırdan farklı olduğu ve diğerlerinin sıfıra yakın olduğu gözlemlenmiştir. Dönüştürülen sinyallerdeki bu N/3 kısmının sınıflandırıcıya girdi olarak seçildiği gözlemlenmiştir. CVSC elde edilmesi için de Ayrık Fournier Dönüşümü (DFT) kullanıldığı belirtilmiştir. DFT sonrası elde edilen CVSC'lere karmaşık değerli sinir ağı (CVANN) uygulanmıştır. Bu yöntem ile 10 kat çapraz doğrulama veri seçimi ile %95,19 başarı oranı alırken %50 eğitim, %50 test veri seçimi ile %94,23 başarı oranı elde etmişlerdir. Yazarlar bu çalışmada CVWANN yönteminin seçilmesinin sebebini, CVWANN algoritmasının fonksiyonelliğinin yüksek ve sınıflandırma kabiliyetinin iyi olmasından dolayı olduğunu belirtmişlerdir.

Sualtı objelerinin sınıflandırılması alanında gerçekleştirilmiş bir çalışmada [9], iki farklı sualtı objesinden dönen sinyale göre hedefin silindirik mayın veya silindirik kaya olup olmadığı tespit edilmektedir. Bu çalışmada gizli katman sayısının ve görüş açısının sonuç üzerindeki etkilerini karşılaştırmak amacı ile farklı gizli katmanlarda ve görüş açısına bağlı ve bağlı olmayan denemeler yapılmıştır. Çalışmalarda en yakın komşu sınıflandırması (K-NN: Nearest Neighbor Classification) yöntemi kullanılmıştır. En son elde edilen sonuçlar ile bu sinyalleri inceleyen insanların performansı karşılaştırılmış ve insan performansının çalışmalarının yanında düşük kaldığı tespit edilmiştir. Elde edilen en yüksek doğruluk oranı %90,4 değeri, görüş açısına bağımlı ve 12 gizli katman ile yapılan denemede elde edilmiştir.

Bu problem üzerine gerçekleştirilen bir başka çalışmada [13] ise, 9 adet örnek tabanlı genetik algoritma (GA) sınıflandırıcısı, genelleme yeteneği ve eğitim verimliliği konusunda daha iyi bir performans bulmak için çeşitli varyasyonlarda kullanılmış ve bu varyasyonların sonucunda elde edilen başarımlar karşılaştırılmıştır. Bahsedilen 9 yöntem, 19 adet veri seti ile denenmiştir. Sonar veri setinin en yüksek başarı oranının TS2 adı verilen modelde %53,43 olduğu görülmüştür.

C4.5 karar ağacını kullanan başka bir çalışmada [14], Bilgi Kazanımı (BK) öznitelik değerlendirme işlemi eklenmesi ile C4.5 karar ağacının başarımının iyileştirilmesi ile sonar hedeflerinin sınıflandırılması problemi üzerine çalışılmıştır. Bu çalışmada dikkat çekilen bir diğer nokta ise, öznitelik seçiminin, sınıflandırma doğruluğunu arttırırken hesaplama verimliliğini de iyileştirmeye yardımcı olduğunu göstermesidir. BK ile birlikte çalışılan C4.5 algoritmasının doğruluğunun %10'dan fazla artarak %81 olarak elde edildiği belirtilmiştir.

Sonar sinyallerinin analizi üzerine yürütülen bir diğer çalışmada [15], sonar sinyallerinin kesintisiz bir veri akışı ile büyüklüğü giderek artan bir veri setine dönecek olması ve bu büyüklüğün performans konusunda yaratacağı problemler incelenmiştir. Sonar sinyalleri gibi sürekli akışa sahip olan verilerin, gerçek zamanlı olarak algılanması için veri işleme süresinin mümkün olan en kısa noktada tutulması gerekliliği vurgulanmıştır. Bu çalışmada bu soruna çözüm olarak, hızlı çakışma analizinin kullanılarak gürültülü verilerin aşamalı olarak temizlenebilmesi için tasarlanmış iDSM-CA adı altında yeni bir strateji sunulmuştur. Bu strateji ile toplamda 6 adet sınıflandırma algoritması ile sonar sınıflandırma testi yapılmıştır.

Benzer bir problem üzerine yürütülmüş bir başka çalışmada [16], sınıflandırma alanında algoritmaların bulunması gereken karar sınırının karmaşıklığının çözülmesi amaçlanmıştır. Bu sorunu çözmek amacıyla, sınıflandırma için, Artımlı Maksimum Gauss Karışımı Bölümü (IMGMP) algoritması önerilmiştir. Bu algoritma uygun bir karar sınırını hesaplamak için böl ve yönet stratejisi kullanmaktadır. Veriyi kümelere ayırmak için K-Ortalamlar algoritması kullanılmıştır. Karar sınırının oluşturulmasında IMGMP'nin performansının yüksek ölçüde küme boyutuna bağlı olduğu vurgulanmıştır ve %82,79 doğruluk oranında sonuç elde edilmiştir.

Bir diğer çalışmada ise [17], en yakın komşu sınıflandırması K-NN algoritmasının, veri seti büyüklüğü arttığı durumlarda, hesaplama maliyetinin artıyor olmasından dolayı oluşan bu sorunu çözmek için yeni bir algoritma önerilmektedir. K-NN algoritması eğitim verileri ile test verilerinin arasındaki mesafeyi hesaplayarak işlem yaparken, veri setinin büyümesi sonucu bu hesap karmaşıklığının artmasından dolayı, sınıf içi mesafeyi minimum ve sınıflar arası mesafeyi maksimum düzeye çıkaracak olan MIME-K-NN algoritması önerilmiştir. Çalışmalar sonucunda K-NN algoritması %74,50 doğruluk

oranı sağlarken MIME-K-NN algoritmasının doğruluk oranı %82,20 olarak elde edilmiştir. Literatürde incelenen ve tüm çalışmalara ait sonuçların başarımlarını ölçütleri Sonuçlar bölümünde Tablo 1’de verilmiştir.

**Tablo 1.** Literatürde rapor edilen deney sonuçları  
(Comparison of results obtained from studies in literature review)

	Kullanılan Yöntem	Doğruluk (%)
[9]	12 gizli katmanlı K-NN	90,40
	Gradyan Artırma	90,00
[10]	K-NN	80,00
	DTA	78,00
[11]	GRNN	91,34
	GRNN - PCA	93,26
[12]	CVANN-CVSV	95,19
	RS1	49,50
	RS2	51,95
	RSU	51,40
	TS1	51,93
[13]	TS2	53,43
	TSU	49,98
	RW1	51,93
	RW2	52,88
	RWU	51,38
[14]	C4.5 with BK	81,00
	NBup with iDCM-CA	82,50
	SVM with iDCM-CA	60,00
[15]	NN with iDCM-CA	88,75
	DT with iDCM-CA	96,25
	IBK with iDCM-CA	85,00
	LWL with iDCM-CA	96,25
[16]	IMGMP	82,79
[17]	MIME-KNN	82,20
Önerilen Yöntem	Zaman serisi-görüntü dönüşümü metodu ve CNN	98,55

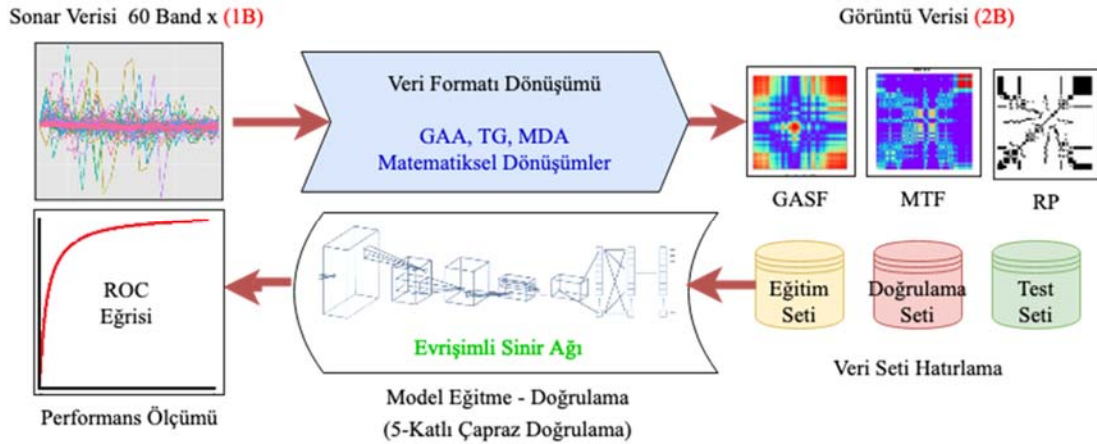
Günümüzde derin öğrenme algoritmalarının görüntü işleme ve bilgisayarlı görü problemlerinde kullanımı oldukça yaygındır. Sınıflandırma [18, 19] ve nesne tespiti [20] problemlerinde birçok alanda etkin biçimde kullanılabilen bu algoritmalar, halihazırda evrimsel sinir ağları

yaklaşımları ile öznelik çıkarım işlemlerini veriden kendisi yapabilmektedir. Klasik makine öğrenmesi algoritmalarının başarısı öznelik çıkarımının kalitesiyle doğru orantılı olduğu düşünüldüğünde, derin öğrenme mimarilerinin veriden kendi kendine öznelik çıkarma yeteneği problemlerin çözümünde oldukça büyük avantaj sağlamaktadır. Sonar verileri görüntü tabanlı olabileceği gibi aynı zamanda zaman serisi türünde de karşımıza çıkabilmektedir. Bu literatür araştırması sonucunda, sonar sinyalleri özelinde, bir boyutlu zaman serisi verisi türündeki sinyallerin, iki boyutlu görüntülere matematiksel dönüşümler vasıtasıyla çevrilerek derin öğrenme algoritmaları ile işlenmesi yöntem ve yaklaşımlarına rastlanmadığı tespit edilmiştir.

### 3. TEORİK ALTYAPI (THEORETICAL BACKGROUND)

Önerilen yöntem temel olarak zaman serisi türündeki verilerin üç kanallı (KYM) ya da tek kanallı (gri) kayıpsız resim formatına dönüştürülmesi esasına dayanmaktadır. Bu dönüşümde her frekans bandındaki verilerin uzamsal ve zamansal değişimleri farklı şekilde ele alınarak tek boyutlu veri dönüşümünden geçirilerek üç boyutlu bir resim formatına dönüştürülür. Yeni dönüştürülen bu resim formatında tek boyutta kullanılmayan ya da elde edilemeyen ancak sınıflandırmada başarımları arttırabilecek yardımcı özneliklerin ortaya çıkması sağlanabilmektedir. Zaman serisi verileri görüntü temsiline dönüştürüldüğünde, bu resimler üzerinde görüntü işleme yöntemleri kullanılarak sınıflandırma problemi çözülebilmektedir. Sonar cihazından 60 farklı banttı elde edilen 208 farklı sinyal, zaman serisi formatında bir veri seti olarak yayımlanmıştır [9].

Şekil 1’de önerilen yöntem için akış diyagramı verilmiştir. İlk olarak zaman serisi formatındaki veriler, belirli özellikler taşıyan farklı matematiksel dönüşüm metotları kullanılarak görüntü formatına (KYM) dönüştürülmektedir. Çalışmada zaman serisi verisinin görsel dönüşümü Gramian Açıl Alan (GAA), Markov Geçiş Alanı (MGA) ve Yineleme Grafiği (TG) adı verilen üç farklı yöntem ile gerçekleştirilmiştir. Bu dönüşüm yöntemleri kullanılarak



**Şekil 1.** Önerilen yöntem için akış diyagramı (Flow chart for the proposed method)

elde edilen resimler ile yeni bir veri seti oluşturulmuştur. Literatürde bilinen eğitim ve test verilerinin ayrılması için kesin bir yöntem olmamakla birlikte, uygulama ve veri setine bağlı olarak genellikle büyük veri setlerinde ve küçük veri setlerinde farklı yaklaşımlar sergilenmektedir ve üzerinde halen araştırmalar yürütülen bir bilimsel problemdir [21]. Ancak, bu çalışmada veri setinin sınırlı sayıda veri ihtiva etmesinden ötürü, klasik makine öğrenmesi algoritmalarının ve önerilen yöntemin performansını daha gerçekçi olarak ölçülebilmesi için veri setinin %67'si eğitim ve %33'ü test için kullanılmıştır. Derin öğrenme teknikleri arasında, görüntü işleme alanında oldukça başarılı olan ESA (CNN) mimarisi kurularak çapraz doğrulama yöntemi ile eğitilmiş ve sınıflandırma başarısını test edilmiştir. Önerilen yöntem özelinde aşağıdaki maddelerde özetlenmiş adımlar takip edilmektedir:

- Veri setindeki her bir verinin 60 farklı frekans bandındaki değeri kullanılarak GATA, MGA ve TG dönüşümlerinin gerçekleştirilmesi,
- Dönüşüm sonucunda elde edilen matris formatındaki sonucun görüntü formatı olarak KYM kanallarına bilgi olarak sağlanması ve (224x224x3) boyutlarında resim formatında dönüştürülmesi,
- Resim formatındaki veriler için ayrı ayrı GATA, MGA ve TG dönüşümleri için yeniden veri seti oluşturulması,
- Yeni veri setlerinin her birisinin %66 eğitim ve %33 test seti olacak şekilde bölünmesi,
- Her bir yeni veri seti için, farklı ESA mimarileri kullanılarak, bu mimarilerin eğitilmesi ve sınıflandırma metrikleri kullanılarak başarımlarının değerlendirilmesi.
- Belirtilen adımlarda kullanılan tüm yöntemler ve bu yöntemlerin detaylı olarak açıklamaları, takip eden alt bölümlerde verilmiştir.

### 3.1. Zaman Serisi-Görüntü Dönüşümü Yaklaşımı (Time Series-Image Transformation Approach)

Bu yaklaşımda, temel olarak tek boyutta zaman serisi formatında temsil edilen verinin, konumsal ve zamana göre değişim bilgisini içeren iki boyutlu görüntü formatında temsil edilmesi hedeflenmektedir. Bu dönüşümü elde etmek için 3 farklı matematiksel yöntem kullanılmıştır. Bu yöntemler sırasıyla Gramian Açısız Alan (Gramian Angular Field/GAF), Markov Geçiş Alanı (Markov Transition Field/MTF) [22, 23] ve Tekrarlama Grafiği (Recurrence Plot/RP) [24, 25] olarak kullanılmıştır. GAA ve MGA metotları ile dönüştürülen değerler KYM renk haritası ile temsil edilmiştir. Renk haritası içerisinde mavi ve mavimsi yakın olan renkler daha küçük değerleri temsil ederken kırmızı ve kırmızıya yakın renkler daha büyük genlikli değerleri temsil eder. TG ise siyah beyaz yani tek kanallı bir görüntü olarak edilmektedir. Zaman serisi verilerinin özellikleri, dönüştürüldükleri görüntüdeki karşılık gelen konumlardaki renk, noktalar ve çizgiler ile 2 boyutlu görüntüler olarak tanımlanmaktadır ve birbirlerinden farklılık göstermektedir. Belirtilen matematiksel dönüşüm yöntemleri ile elde edilen yeni formatlı veri, verinin görüntü formatında ihtiva ettiği bilgileri kullanabilen derin öğrenme

algoritmalarının kullanımını mümkün kılmaktadır. Bu yaklaşımı ifade etmek için:  $f$  birebir ve örten olacak şekilde bir fonksiyon tabanlı eşlemeyi göstermektedir. Bu eşleme Eş 1-5 ile gösterilmektedir:

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

$$Z = f(X) \text{ ve } X = f^{-1}(Z), x \in \mathbb{R}^{1 \times n_i}, z \in \mathbb{R}^{n_o \times n_o} \quad (2)$$

$$Z_{GAF} = f_{GAF}(X) \quad (3)$$

$$Z_{MTF} = f_{MTF}(X) \quad (4)$$

$$Z_{RP} = f_{RP}(X) \quad (5)$$

Bu tanımlamada,  $n_o$  eşlemenin çıkış boyutunu,  $n_i$  eşlemenin giriş uzayındaki boyutunu,  $x$  giriş uzayı vektörünü,  $z$  eşleme uzayı tensörünü tanımlamaktadır. Temel yaklaşım her bir eşleme fonksiyonu ( $f_{GAF}$ ,  $f_{MTF}$ ,  $f_{RP}$ ) vasıtasıyla elde edilen farklı veri dönüşümlerinin elde edilmesidir.

#### 3.1.1. Gramian açısız alan dönüşümü (Gramian angular field / GAF)

Gramian açısız alan dönüşümü, zaman serisi verisinin Kartezyen koordinat düzlemi yerine polar koordinat düzleminde temsil edilmesini sağlamaktadır. GAA'da her bir elemanın değeri, dönüşüme uğrayacak zaman noktasındaki verilerin, polar düzlemde, açısız karşılıklarının toplamının kosinüs fonksiyonunda elde edilen değeri olarak belirlenir. GAA'nın dönüşüm için iki farklı yöntemi bulunmaktadır. Bu yöntemler Gramian Açısız Toplama Alanı (Gramian Angular Summation Field/GASF) ve Gramian Açısız Fark Alanı (Gramian Angular Difference Field/GADF)'dir. Gramian açısız alan yönteminde verilen zaman serisindeki her bir nokta yeniden ölçeklendirilir ve her bir değer  $[-1,1]$  ya da  $[0,1]$  aralığına düşmesi sağlanır. Bu ön işleme adımı için gerekli matematiksel ifadeler Eş. 6 ve Eş. 7'de verilmiştir:

$$\tilde{x}_{-1}^i = \frac{(x_i - \max(X) + x_i - \min(X))}{\max(X) - \min(X)} \quad (6)$$

$$\tilde{x}_0^i = \frac{x_i - \min(X)}{\max(X) - \min(X)} \quad (7)$$

Burada  $x_i$  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. 5'de verinin  $[-1,1]$  aralığına, Eş. 6'da ise veri değerlerinin  $[0,1]$  aralığına ölçeklenmesi, sırası ile "-1" ve "0" alt indisleri ile gösterilmiştir. Ölçekleme sonrasında elde edilen yeni zaman serisi değerleri, açısız olarak kosinüs fonksiyonunda hesaplanması ve zaman damgasını olarak da yarıçap değerinin kodlanması ile kutupsal koordinat düzleminde ifade edilir. Dönüşümün matematiksel ifadeleri Eş. 8, Eş. 9 ve Eş. 10'da verilmiştir.



$$X^{Polar} = \begin{cases} \varnothing = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, t_i \in \mathbb{N} \end{cases} \quad (8)$$

$$GATA = \begin{bmatrix} \cos(\varnothing_1 + \varnothing_1^N) & \cdots & \cos(\varnothing_1 + \varnothing_n) \\ \vdots & \ddots & \vdots \\ \cos(\varnothing_n + \varnothing_1) & \cdots & \cos(\varnothing_n + \varnothing_n) \end{bmatrix} \quad (9)$$

$$GATA = \tilde{X}' \cdot \tilde{X} - \sqrt{I - \tilde{X}'^2} \cdot \sqrt{I - \tilde{X}^2} \quad (10)$$

Bu eşitliklerde, dönüşüm sonrasında elde edilen  $\varnothing$  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 olarak verilmektedir.  $X^{Polar}$  dönüşüm sonrasında elde edilen matrisi, GATA ise Gramian açısıl toplama alanını ifade etmektedir. Benzer şekilde önışleme sonrasında, Gramian açısıl fark alanı (GAFA) ise Eş. 11 ve Eş. 12 ile elde edilebilmektedir:

$$GAFA = \begin{bmatrix} \sin(\varnothing_1 - \varnothing_1) & \cdots & \sin(\varnothing_1 - \varnothing_n) \\ \vdots & \ddots & \vdots \\ \sin(\varnothing_n - \varnothing_1) & \cdots & \sin(\varnothing_n - \varnothing_n) \end{bmatrix} \quad (11)$$

$$GAFA = \sqrt{I - \tilde{X}'^2} \cdot \tilde{X} - \tilde{X}' \cdot \sqrt{I - \tilde{X}^2} \quad (12)$$

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 2'de gösterilmektedir.

### 3.1.2. Markov geçiş alanı dönüşümü (Markov transition field / MTF)

MGA dönüşümünde, verilen bir  $X$  zaman serisinde,  $Q$  dağılım dilimleri ve zaman serisindeki her  $x_i$  ile ilişkili  $q_i$  dilimleri ile tanımlanmaktadır. Böylece zaman eksenini boyunca Markov zinciri şeklinde dağılım dilimleri arasındaki geçişler hesaplanarak  $Q \times Q$  ağırlıklı yakınlık

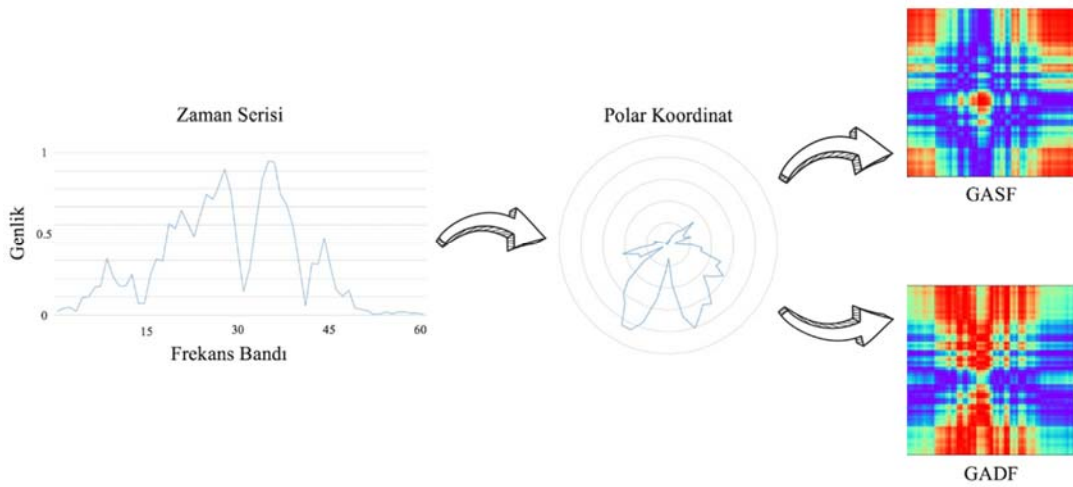
matrisi oluşturulmaktadır. Oluşturulan bu matristeki her  $w_{i,j}$ ,  $q_j$  dağılım dilimine ait bir nokta ve o noktayı takip eden  $q_i$  dağılım diliminin bir noktasının gelme sıklığı ile belirlenmektedir. Bu belirleme işlemi matristeki tüm elemanlar için yapıldıktan sonra matris  $\sum_j w_{ij} = 1$  eşitliğine göre normalize edildiğinde Markov geçiş matrisi elde edilmektedir. Elde edilen Markov geçiş matrisi  $x$ 'in dağılımına duyarsızdır ve zamansal bağımlılığı bulunmamaktadır [23]. Eş. 13'de verilen denklemde, verilerin  $Q$  dağılım dilimine bölünmesiyle elde edilen Markov geçiş matrisi gösterilmektedir:

$$M = \begin{bmatrix} w_{ij|x_1 \in q_i, x_1 \in q_j} & \cdots & w_{ij|x_1 \in q_i, x_n \in q_j} \\ w_{ij|x_2 \in q_i, x_1 \in q_j} & \cdots & w_{ij|x_2 \in q_i, x_n \in q_j} \\ \vdots & \ddots & \vdots \\ w_{ij|x_n \in q_i, x_1 \in q_j} & \cdots & w_{ij|x_n \in q_i, x_n \in q_j} \end{bmatrix} \quad (13)$$

Uygulanan bu dönüşüm ile elde edilen olasılık tabanlı matris, 3 kanallı KYM renk bilgisi içeren bir resim formatında kodlanarak dönüşüm işlemi tamamlanmış olur. Açıklanan yöntemin bir uygulaması Şekil 3'de gösterilmiştir.

### 3.1.3. Tekrarlanma grafiği (Recurrence plot / RP)

Tekrarlanma grafiği; zaman serileri, periyodik veriler ve döngüler gibi tekrarlayan süreçler için kullanılan ve bu süreçleri iki boyutlu olarak görselleştiren bir metottür. RP ayrıca doğrusal olmayan veri analizinin uygulamalarında sıkça kullanılan gelişmiş bir tekniktir. Tekrarlanma grafiklerinin temel amacı, yüksek boyutlu faz uzayı yörüngelerinin görsel olarak incelenmesidir. RP yöntemi ile dönüşüm işlemi, kısa ve durağan olmayan verilere de uygulanabilmektedir. Tekrarlanma Grafiği yönteminde zaman serisindeki her bir noktanın, zaman serisine olan uzaklığı hesaplanarak görüntü oluşturulur. Zamana bağlı bir davranışı görselleştirmek için çalışan bu yöntemde, görselleştirmenin ana adımı, zaman serisinden elde edilen  $N \times N$  boyutlu matrisin hesaplanmasıdır [24]. Bir faz uzayında  $x_i$  durumlarının tekrarını görselleştirebilen bir araç olması



Şekil 2. Gramian açısıl alan dönüşümü (Gramian angular field transformation)

amacıyla geliştirmiştir. Bu araç,  $m$  boyutlu faz uzay yörüngesini ve tekrarlarını, iki boyutlu bir temsil yoluyla araştırmamızı sağlar. Farklı bir zamanda bir durumun benzer biçimde tekrarlanması, iki boyutlu kare matris içinde bir ve sıfır değerleri ile (grafikteki siyah ve beyaz noktalar) işaretlenir. Bu gösterim ile tekrarlanma grafiği (RP) edilmektedir. Elde edilen iki değerli matris, 1 kanallı renk kodlaması içeren bir resim formatında kodlanarak dönüşüm işlemi tamamlanmaktadır. Tekrarlanma grafiğinin matematiksel olarak gösterimi ise Eş. 14'te gösterilmiştir.

$$R_{i,j} = \Theta(\varepsilon - \|\vec{x}_i - \vec{x}_j\|), i, j = 1 \dots N \quad (14)$$

Bu eşitlikte  $\varepsilon$  önceden tanımlanmış eşik değer,  $N$  hesaplanacak veri sayısı ve  $\Theta$  basamak fonksiyonudur.  $R_{i,j}$  değerleri basamak fonksiyonu sebebi ile 1 veya 0 olmalıdır [25]. Tekrarlanma grafiği noktalar, çapraz, dikey/yatay çizgiler ve bloklardan oluşmaktadır. Tekrarlanma grafikleri de diğer görüntü dönüşümleri (GAA/MGA) gibi görsel olarak kolayca tanımlanamazlar. Bu sebeple ESA'lar bu görselleri kategorilere ayırmak ve özelliklerini öğrenmek için kullanılabilir. Açıklanan yöntemin bir uygulaması Şekil 4'de gösterilmiştir.


### 3.1.4. TG, MGA ve GAA dönüşümlerinin karşılaştırılması (Comparison of MTF, GAF and RP methods)

Tekrarlanma grafiği (TG), doğrusal olmayan veri analizinin gelişmiş bir tekniğidir. Burada elde edilen kare matrisin öğeleri dinamik bir sistemin durumunun tekrarlandığı zamanlara karşılık gelmektedir. Teknik olarak TG, dinamik sistemin faz uzayı yörüngesi faz uzayında kabaca aynı alanı


ziyaret ettiğinde her zaman ortaya çıkar ve daha yakından incelendiğinde, tek noktalar, diyagonal çizgiler ve dikey ve yatay çizgiler (dikey ve yatay çizgilerin birleşimi açıkça dikdörtgen tekrarlanma noktaları kümeleri oluşturan) olan küçük ölçekli dokusal (texture) yapıları ortaya çıkarır. Birinci dereceden geçiş olasılığını zamansal olarak matrise sıralı bir şekilde dağıtan Markov geçiş alanı yöntemi, farklı zaman gecikmeleri arasındaki geçiş/dönüşüm dinamiklerini kodlayabilmektedir. Farklı zaman serilerinin, zamansal ve frekans alanlarına gömülü özel geçiş dinamiklerine sahip olduğu varsayımı ile MGA tarafından özneliklerin yeniden hesaplanması işleminden sonra, görsel olarak incelenebilen çoklu geçiş/dönüşüm dinamikleri elde edilmektedir. MGA, zaman serilerinin önemli özellikleri olan geçiş/dönüşüm dinamiklerini görsel olarak kodlarsa da bu özellikler, tanıma / sınıflandırma problemlerinin çözümleri için her zaman yeterli olmayabilmektedir. Gramian açısız alan (GAA) dönüşümü, zaman aralığına göre yönlere süper pozisyonun bir sonucu olarak zamansal korelasyonlar üretirken değerler arasındaki zamansal bağımlılık özelliğini korumaktadır. Ortaya çıkan dönüşüm matrisi, çift yönlü olarak kullanılabilen bire bir ve örten bir özelliktedir. Bu nedenle, ters fonksiyon olarak kullanıldığında, orijinal verilerin mutlak bir yeniden yapılandırmasını ya da elde edilmesine olanak sağlar.

### 3.2. Veri Seti (Data Set)

Bu çalışmada kullanılan veri seti [9] silindirik mayınlar ve bu mayınlara şekil olarak benzeyen ancak silindirik kayalardan farklı açılardan yansıyan sinyaller ile



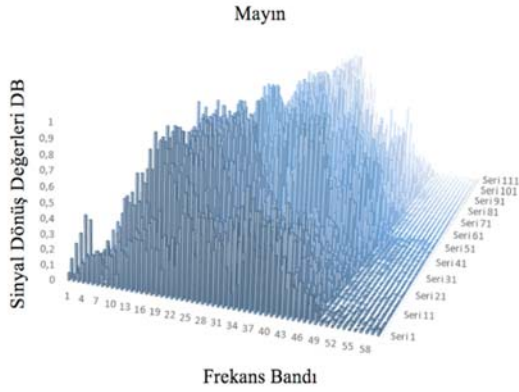
Şekil 3. Markov geçiş alanı dönüşümü. (Markov transition field transformation)



Şekil 4. Tekrarlanma grafiği yöntemi. (Recurrence plot method)

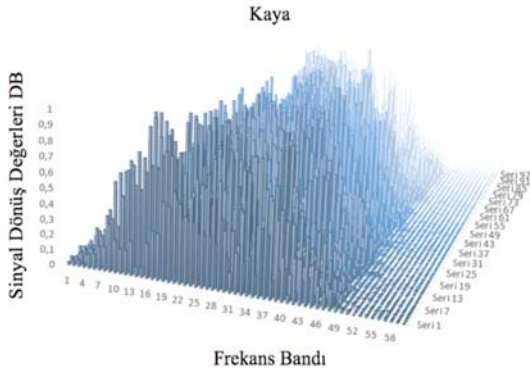


oluşturulmuştur. Sonar veri setinin elde edildiği silindirik mayın ve silindirik kayaların boyları yaklaşık 5 ft uzunluğundadır. Veri setinde toplam 208 adet veri bulunmaktadır. Bu veriler su altında bulunan kayalar ve silindirik mayınlara, kayalar için 180 derece ve mayınlar için 90 dereceye kadar olmak şartı ile farklı açılardan gönderilmiş sinyallere geri dönüş olarak gelen 1200 adet sinyalden, her görüş açısından rastgele seçilecek ortalama 5 dönüş alınarak elde edilmiştir. Elde edilen 208 adet veriden 111 tanesi silindirik mayına, 97 tanesi de silindirik kayaya aittir. Her veri 0,0 ile 1,0 aralığında 60 sayılık bir settir.



**Şekil 5.** Tüm mayın hedefleri için ölçüm yapılan frekans bandına karşılık sinyal dönüşü değerleri  
(Signal return values corresponding to the frequency band measured for all mine targets.)

Her sayı belirli bir frekans bandında sabit bir süre boyunca toplanan enerjiyi temsil eder. Her sayı tam olarak açı değerini yansıtmasa da artan bir açı sırasına göre sıralanmıştır. Her veriye ait sınıflandırmada veri kaya ise R, mayın ise M olarak etiketleme yapılmıştır. Şekil 5 ve Şekil 6'da veri setinde olan tüm mayınlara ve tüm kayalara ait olan zaman serisi ekseninde sonar sinyal dönüşlerinin grafiği verilmiştir.



**Şekil 6.** Tüm Kaya hedefleri için ölçüm yapılan frekans bandına karşılık sinyal dönüşü değerleri.  
(Signal return values corresponding to the frequency band measured for all rock targets.)

### 3.3. Makine Öğrenmesi Yöntemleri ile İkili Sınıflandırma Probleminin Çözümü (Solution of Binary Classification Problem with Machine Learning Methods)

Bu çalışmada, ikili sınıflandırma problemi için literatürde sıkça karşılaşılan klasik makine öğrenmesi algoritmaları seçilmiş ve başarımları algoritma özelinde hiperparametre optimizasyonu ile en iyi hale getirilmiştir. Seçilen klasik makine öğrenmesi algoritmaları: Destek Vektör Makinesi, Karar Ağacı Algoritması, K-En Yakın Komşu Algoritması, Doğrusal Ayrıcılık Analizi, GaussianNB, Lojistik Regresyon ve Rassal Orman algoritmalarıdır. Aşağıdaki alt bölümlerde bu yöntemler kısa açıklanmış ve karşılaştırılmıştır:

#### 3.3.1. Evrişimli sinir ağları / ESA (Convolutional neural network / CNN)

Evrişimli sinir ağı, görüntü sınıflandırma, ses işleme ve benzeri veri dizilerini işleyebilen öğrenilebilir ağırlıklara sahip nöronlardan oluşan çok katmanlı algılayıcıların bir türü olan derin sinir ağıdır. Evrişimli sinir ağının katmanları; Evrişim (Convolutional), Havuzlama (Pooling) ve Tam Bağlı (Fully Connected) olarak adlandırılır. Evrişim katmanında belirli bir filtre tüm görüntü üzerinde dolaştırılarak bir dönüşüm işlemi yapılır. Bu dönüşüm işlemi sırasında filtre boyutları değişiklik gösterebilmektedir ve işlem sonrasında bir çıkış verisi oluşturulur. Havuzlama katmanı evrişimli sinir ağının öğrenmesi gereken parametre sayısının azaltılması işlemi yapar ve bu sayede bu katmandan sonra elde edilecek çıkışı basitleştirir. Evrişimli katmanlar ve havuzlama katmanları mimari içerisinde tamamlandıktan sonra tam bağlı katman ile sınıfların olasılıkları tutulur. Evrişimli sinir ağlarının gelişmiş öğrenme yetenekleri sayesinde, yapılacak olan ön işlemenin diğer algoritmalara kıyasla çok az olması bu ağın en önemli avantajları arasında sayılmaktadır.

Gerekli filtrelerin uygulanması ile girdi olarak verilen görüntülerdeki uzamsal ve zamansal bağımlılıkları yakalayabilen bu ağ görüntünün karmaşıklığını daha iyi anlamak ve veri setine daha iyi uyum sağlamak için ağırlıklarının yeniden kullanılabilir olması sayesinde daha iyi sonuçlar için eğitilebilmektedir. Evrişimli sinir ağında katmandaki vektörler bir önceki vektöre ait küçük bir girdi alır. Her vektör kendisinden önceki katmanda bulunan vektör üzerinden küçük bir pencere ile taranır. Bu tarama işlemi sonucunda bir özellik haritası oluşturulur ve bu özellik haritası tüm havuzlama katmanlarına bir önceki evrişim katmanından geçerek gönderilir. Son havuzlama katmanına gelindiğinde ise son katmandan alınan özellik haritası düzleştirilir ve tam bağlı katmana gönderilir. Başka bir deyişle, evrişimli katmanın ana görevi, önceki katmandaki özelliklerin yerel birleşimlerini tespit etmek ve görünümünü bir özellik haritasına eşlemektir. Nöron ağlarındaki evrişimin bir sonucu olarak, görüntü algılayıcılara bölünür, yerel alıcı alanlar oluşturur ve son olarak algılayıcıları  $m_2 \times m_3$  boyutundaki özellik haritalarında sıkıştırır. Böylece, bu harita, özelliğin görüntüde nerede meydana geldiği ve filtreye ne kadar iyi

karşılık geldiği bilgisini saklar. Bu nedenle, her filtre uygulandığı hacimdeki konuma göre uzamsal olarak eğitilir. Evrişimli katmanın ana görevi, önceki katmandaki özelliklerin yerel birleşimlerini tespit etmek ve görünümlerini bir özellik haritasına eşlemektir. Her katmanda,  $m_i$  filtre bankası vardır. Bir aşamada kaç tane filtrenin uygulandığı, çıktı özelliği haritalarının hacminin derinliğine eşittir. Her filtre, girişin her konumunda belirli bir özelliği algılar. Evrişim katmanının yapısı matematiksel olarak Eş. 15 ve Eş. 16'da gösterilmiştir.

$$Y_i^{(k)} = B_i^{(k)} + \sum_{j=1}^{m_1^{(k-1)}} F_{i,j}^{(k)} * Y_j^{(k-1)} \quad (15)$$

$$O_i^{(k)} = f(Y_i^{(k)}) \quad (16)$$

Bu denklemde,  $Y_i^{(k)}$ ,  $k$ 'nci katmandaki  $i$ 'nci çıkış değeri,  $m_1^{(k)}$  öznelik haritası için  $m_2 \times m_3$  boyutundaki filtre değerleri ile hesaplanmaktadır. Bununla birlikte,  $O_i^{(k)}$  çıkış katmanındaki değeri,  $B_i^{(k)}$  bias matrisi değerlerini,  $F_{i,j}^{(k)}$  ise katman  $(k-1)$  deki  $j$ 'nci ve  $i$ 'nci öznelik haritası arasında bağlantıyı sağlayan  $(2h_1^{(k)} + 1) \times (2h_2^{(k)} + 1)$  boyutlarında filtreyi ve  $f$  ise aktivasyon fonksiyonunu göstermektedir. Evrişim katmanlarının, bu katmanları takip eden diğer katmanlarla birlikte sıralı olarak bir araya getirilmesi sonucu, görüntünün içerdiği bilginin hiyerarşik olarak bölünmesi sağlanır. Böylelikle bu işlem sonunda, piksellerin kenarlara, kenarların motiflere, motiflerin parçalara, parçaların nesnelere ve nesnelere sahnelere halinde birleştirildiği anlamına gelmektedir. Her bir evrişim katmanında ve diğer nöron modellerinde aktivasyon fonksiyonları kullanılmaktadır. Evrişim katmanlarından oluşan bu yapı son olarak bir düzleştirme işlemine tabi tutularak tam bağlantılı katman ile birleştirilir. Çok katmanlı nöron ağı (Multilayer perceptron) ve çıkış katmanında sınıflandırma olasılık değerlerini verecek softmax aktivasyon fonksiyonu ile klasik bir mimari oluşturma işlemi tamamlanmaktadır. Çıkış katmanındaki değerlere göre o verinin ait olduğu sınıf bilgisi elde edilmektedir.

### 3.3.2. Destek vektör makineleri algoritması / DVM

(Support vektor machine algorithm / SVM)

Gözetimli bir öğrenme algoritması olan Destek Vektör Makineleri algoritması veriler arasında bir karar sınırı bularak verileri birbirinden ayırmak için hiper düzlemler belirleyen vektör uzayı tabanlı bir algoritmadır. 1990'lı yıllarda Vapnik ve grubu tarafından AT&T Bell Laboratuvarlarında önerilen bir sınıflandırıcı modeli olan destek vektör makineleri, pratikte yüksek genelleme kabiliyetine sahip etkili modellerden biridir [26]. DVM algoritması verileri birbirinden ayırmak için kullanacağı karar doğrusunu, yeni eklenecek verilere karşı da kullanılabilir olması için, verilere ait sınıfların sınır çizgilerine en yakın uzaklıkta olacak şekilde belirlemektedir. Yüksek boyutlu verilerde etkili olması, kullandığı eğitim noktaları sayesinde bellek kullanımını daha verimli hale getirmesi ve farklı çekirdek fonksiyonları ile çok yönlü karar

verebilmesi DVM algoritmasının avantajları arasında yer almaktadır. DVM kendisine verilen veri setinin doğrusal olarak ayrılıp ayrılamama durumlarına göre farklı çözümler sunmaktadır. DVM doğrusal olarak ayrılmayan veriler ile başa çıkabilmek için çekirdek yöntemlerini kullanır çünkü bu yöntemler verilere ait orijinal özelliklerin doğrusal olmayan kombinasyonlarını oluşturarak bu yöntemleri doğrusal olarak ayıran bir eşleme yapar ve bu eşleme sayesinde eğitim verilerini daha yüksek boyutlu bir özellik alanına dönüştürerek doğrusal bir destek vektör makinesi algoritması ile eğitilebilir duruma getirir. Tüm bu işlemler yapılırken veri setinin boyutunun çok yüksek olduğu durumlarda hesaplama maliyeti artacağı için 'kernel trick' adı verilen çekirdek hilesi yöntemini kullanılmaktadır.

### 3.3.3. Karar ağacı algoritması / KAA

(Decision tree algorithm / DTA)

Karar ağacı algoritmaları hem sınıflandırma hem de regresyon problemlerine çözüm olarak kullanılmaktadır. Karar ağaçları, karar düğümleri ve yaprak düğümlerinden oluşan bir ağaç yapısındadır. Bu algoritmanın temel fikri, verilerdeki temsili bilgilerle en iyi niteliği bulmaktır. Veri seti, iyi tanımlanmış kriterlerle alt gruplara bölünmüş olsa da, bu işlem daha sonra ağacı büyütme için özimizelemeli olarak uygulanır; bu nedenle, durdurma kriterleri doğrulanana kadar her yinelemede veriler kademeli olarak küçülür [27]. Karar algoritması kullanılarak ağaç kökünden başlanır ve en fazla bilgi kazanımı olan özellikler üzerindeki veriler bölünerek düğüm en saf halini alana kadar işlem tekrar edilir. Karar ağaçları bu yöntemle birçok düğümü olan bir ağaç olabilir ve bu da aşırı uyuma sebep olabilir. Karar ağacı algoritmalarında aşırı uyumun önüne geçilmesi için oluşturulacak olan ağacın maksimum düğüm sayısı için sınır belirlenerek budama yapılmalıdır. Karar ağacı algoritması hem sayısal hem de kategorik verilerin işlenmesi için kullanılabilir ayrıca düşük hesaplama maliyetine sahip olduğu için yüksek boyutlu verileri kısa sürede işleyebilir. Bu sebeple alternatif olan algoritmalar arasında veri boyutu arttığında tercih sebebi olmaktadır.

### 3.3.4. K-en yakın komşu algoritması / K-EYK

(K-nearest neighbor algorithm / K-NN)

K-EYK algoritması diğer sınıflandırma algoritmaları arasında en tembel algoritma olarak geçmektedir. Bu durum eğitim veri setinden ayırt edici bir özelliği öğrenme yerine veri setini ezberleme eğiliminde olmasından kaynaklanmaktadır. K-En yakın komşu algoritması, parametrik olmayan örnek tabanlı öğrenme olarak bilinen bir algoritmadır. Bu algoritmadaki model, eğitim veri kümesini ezberler ve bir tahmin yapılması istenildiğinde seçilen mesafe metriğine bağlı olarak veri setindeki algoritmaya verilen  $k$  sayısı kadar en yakın komşuları bulur ve verinin sınıflandırma etiketini çoğunluğa göre belirler [28]. K-EYK algoritması yeni veriler için kolay uyum sağlanmasına imkân tanımaktadır. Ancak bu yeni örneklerin hesaplanmasının maliyetinin en kötü durumda eğitim veri setindeki örnek sayısı ile doğru orantılı olarak artmasının bu algoritmanın en temel dezavantajlarından biri olduğu unutulmamalıdır.

### 3.3.5. Doğrusal ayırmacılık analizi algoritması / DAA (Linear discriminant analysis algorithm / LDA)

DDA algoritması, veri kümesindeki boyutların sayısını azaltmak için kullanılan denetimsiz bir algoritmadır. Doğrusal ayırmacılık analizi algoritması, hesaplama verimliliğini arttırmak ve düzenli olmayan verilerde “boyutun laneti” nedeni ile aşırı uyumu azaltmak için özellik çıkarma tekniği olarak da kullanılabilir [29]. DDA algoritması, N boyutlu bir veri setini standartlaştırarak her sınıf için N boyutlu ortalama vektörü hesaplar. Sınıflar arası ve sınıflar içi dağılım matrisini oluşturur. Burada oluşturulan matrisleri düşük boyutlu özellik uzaylarına dönüştürür. Veri setini ayırtmak için kovaryans matrisini kullanan bir algoritmadır. Fisher’ın skor fonksiyonuna göre çalışmakta ve skoru maksimize eden doğrusal katsayıları tahmin etmektedir. Verileri en iyi açıklayan değişkenlerin doğrusal kombinasyonlarını bulmaya çalışarak işlem yapar ve veri sınıfları arasındaki farkı modellemeye çalışır [30]. Sınıflandırma işlemleri öncesinde özellik çıkarmak ve sınıfları belirlemek için ön işlem olarak kullanılabilir.

### 3.3.6. GaussianNB algoritması / GNB (GaussianNB algorithm / GNB)

GaussianNB algoritması, Naive Bayes algoritma türlerinden bir tanesidir. GaussianNB sürekli değerlerden oluşan özelliklere sahip olduğunda kullanılan gözetimli öğrenme algoritması türüdür. Bayes teoremi temel alınarak geliştirilen bu algoritmada her özellik birbirinden bağımsız kabul edilir bu da lojistik regresyon gibi bağımlı kabul eden modellerden daha iyi performans göstermesine olanak sağlamaktadır [29]. Hem küçük boyutlu verilerde hem de yüksek boyutlu verilerde iyi sonuçlar elde edilebilir. Naive bayes algoritması kullanılmadan önce verinin ön işleminin ve özellik seçiminin çok iyi yapılmış olması gerekmektedir. Çünkü naive bayes algoritmasında sonucu değiştirmek için optimize edilebilecek çok fazla parametre bulunmamaktadır, dolayısı ile bu optimizasyon önce yapılmalıdır.

### 3.3.7. Lojistik regresyon algoritması / LR (Logistic regression algorithm / LR)

Gözetimli makine öğrenme algoritmalarından uygulaması çok kolay ancak doğrusal olarak ayrılabilen sınıflarda daha iyi bir performans gösteren bir sınıflandırma modeli olan lojistik regresyon algoritması sınıflandırma problemlerinin yanı sıra regresyon problemlerinde kullanılmaktadır. Lojistik regresyon, bir bağımlı ikili değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi açıklamak için verilerin tanımlanmasında ve analizinde kullanılır [31]. Doğrusal ve ikili sınıflandırma problemleri için basit ama güçlü bir algoritma olan lojistik regresyon, özellikle tahmin edilmek istenen değişken tipinin kategori türünde olduğu durumlarda daha iyi sonuçlar vermektedir. Lojistik regresyon algoritması bir değişkenin olma olasılığı ile veri setindeki öznitelikleri arasındaki ilişkiyi kurmaktadır. Sadece tahmin edilecek sınıf ile değil, aynı zamanda sınıftaki değişkenin olma olasılığının tahmin edilmesi ile ilgilenir. Lojistik regresyon algoritması bir olayın logaritmik oranını

tahmin eden logit fonksiyonunu kullanır. Logit fonksiyonu, 0 ile 1 aralığında girdi değerlerini alır ve bu verileri bir ilişkiyi ifade etmesi için tüm gerçek sayı aralığı boyunca değerlere dönüştürür.

### 3.3.8. Rassal orman algoritması / RO (Random forest algorithm / RF)

Rassal orman algoritması, birden fazla karar ağacı oluşturarak aşırı uyumun (overfitting) önüne geçebilen hem sınıflandırma hem de regresyon problemlerinde kullanılan bir algoritmadır. Rassal orman algoritmasında verilerin doğrusal olarak ayrılıp ayrılmadığına bakılmaksızın oluşturulan tüm karar ağaçları ile en önemli özelliklerin çıkarımı yapılmaktadır. Rassal orman algoritması klasik karar ağacı algoritmasından farklı olarak bir düğümü alt düğümlere ayırırken en önemli özelliği bulmak yerine rastgele bir özellik alt kümesi içinde en önemlisini bulmaya çalışmaktadır. Rassal orman algoritması, rasgelelik özelliği ile genellikle tek bir karar ağacından daha iyi bir genelleme performansına sahiptir ve bu da modelin varyansını azaltmaya yardımcı olur. Veri kümesindeki aykırı değerlere karşı daha az duyarlıdır ve çok fazla parametre ayarı gerekmeden topluluktaki ağaçların sayısı parametresi ile başarılı bir şekilde çalışabilmektedirler [29].

## 4. DENEYSEL ÇALIŞMA (EXPERIMENTAL STUDY)

Veri setindeki sonar sinyalleri ile zaman serisi üzerinden görüntü transformasyonu yapılmadan önce ilk olarak klasik sınıflandırma yöntemleri olan DVM, KAA, K-EYK algoritması, DAA, GNB, LR ve RO algoritmaları ile modeller eğitilmiş ve test edilmiştir. Her algoritmada, ayrılan test veri seti için ızgara tabanlı hiperparametre arama yöntemi uygulanmış ve sonuçlar not edilmiştir. Klasik makine öğrenme algoritmalarının özelliklerini belirlemek için veri setinde özellik olarak 60 frekans bandından elde edilen enerji seviyeleri kullanılmıştır ve öznitelik seçimi yapılmamıştır. Öznitelik seçimi yapılmamasının başlıca nedeni, literatürde aynı veri seti üzerinde gerçekleştirilmiş çalışmalar içerisinde farklı öznitelik seçimi tekniklerinin hali hazırda denenmiş olması ve bu çalışmadaki sonuçların hem literatürdeki sonuçlar ile hem de klasik algoritmalar ile karşılaştırılacak olmasıdır. Bu çalışmadaki temel amaç, öznitelik seçimi yapılmadan önerilen yöntemin performansının hem literatürdeki yaklaşımlar hem de önerilen yöntemin başarımlarının karşılaştırılmasıdır. Önerilen yöntemin ESA’larının karakteristik özelliği olan kendiliğinden öznitelik seçimi yapabilmesi özelliğini de yöntem içerisinde kullanılabilmesinin sağlanmasıdır. Zaman serisi-görüntü dönüşümü yöntemleri ile elde edilen resimlerle, klasik algoritmalarda kullanıldığı gibi aynı sırada olan yeni bir veri seti oluşturulmuştur. Bu çalışmada veri setinin sınırlı sayıda veri ihtiva etmesinden ötürü, klasik makine öğrenmesi algoritmalarının ve önerilen yöntemin performansını daha etkin olarak ölçülebilmesi için veri setinin %67’si eğitim ve %33’ü test için kullanılmış ve test setinde performansın gerçekçi olarak değerlendirilebileceği sayıda verinin bulunması sağlanmıştır. Doğrulama için bir tanesini dışarıda bırak çapraz doğrulama (10-fold leave one

out cross validation) yöntemi uygulanmıştır ve bölütleme değeri (fold) 10 olarak seçilmiştir. Tüm algoritmaların performansı doğruluk, kesinlik, geri çağırma ve  $F_1$ -Skor ölçütleri aşağıda verilen Eş. 17, Eş. 18, Eş. 19 ve Eş. 20'ye göre hesaplanmıştır.

$$\text{Doğruluk} = \frac{GP+GN}{P+N} = \frac{GP+GN}{GP+GN+YP+YN} \quad (17)$$

$$\text{Kesinlik} = \frac{GP}{GP+YP} \quad (18)$$

$$\text{Geri Getirme} = \frac{GP}{GP+YN} \quad (19)$$

$$F_1 = 2 \times \frac{\text{Geri Getirme} \times \text{Kesinlik}}{\text{Geri Getirme} + \text{Kesinlik}} \quad (20)$$

Bu denklemlerde  $G_P$ , gerçek pozitif sayısını,  $G_N$ , gerçek negatif sayısını,  $Y_P$ , yanlış pozitif sayısını,  $Y_N$  ise yanlış negatif sayısını,  $P$  tüm doğru olarak nitelendirilen sonuç sayısını,  $N$  tüm yanlış olarak nitelendirilen sonuç sayısını göstermektedir. Bu değerler kullanılarak kesinlik, geri getirme, doğruluk ve  $F_1$  ölçütü değerleri hesaplanmaktadır.


Sınıflandırma yöntemlerinden ilk olarak DVM algoritması seçilmiştir. Doğrusal olmayan destek vektör makinesi algoritması kernel yöntemlerinden radyal tabanlı fonksiyon ve  $C=1,5$  parametre değerleri ile çalışılmış ve en yüksek başarı oranına ulaşılmıştır. Bu çalışmada kullanılan ve en iyi sonucu veren karar ağacı parametreleri; Gini Bilgi Kriteri, bir düğümü bölmek için gereken minimum örnek sayısı 2, bir yaprak düğümündeki minimum örnek sayısı 1, maksimum yaprak düğümü kullanım dışı, sınıf ağırlığı kullanım dışı, karmaşıklık parametresi 0,0 olarak seçilmiştir. K-En yakın komşu algoritması, bu çalışmadaki veri seti ile k değeri 1 olarak eğitildiğinde en yüksek başarı oranına ulaşmıştır. Ağırlık olarak uniform değeri verilmiş, algoritma olarak auto seçilerek değerlere göre en uygun algoritmaya karar vermesi sağlanmıştır. Bu çalışmadaki veri seti çok sayıda özelliğe sahip olduğu için DAA algoritması parametreleri ile çalışılırken çözücü olarak tekil değer ayrışımı (TDA) kullanılarak kovaryans matrisi hesaplanmamıştır. Bu parametreye ek olarak diğer parametreler küçülme auto, öncelik none, boyut azaltma için bileşen sayısı none, kovaryans depolaması false ve çözücü

TDA olarak kullanıldığı için tolerans değeri  $1,0e-4$  olarak seçilmiştir. GaussianNB bu çalışmada kullanılan veri seti ile en ideal sonuçlara ulaşmak için çalışılan parametrelerde sınıfların önceki olasılıkları belirtilmemiş ve hesaplama kararlılığı için gereken yumuşatma değeri  $1,0e-9$  olarak seçilmiştir. Lojistik regresyon, bu çalışmada veri seti ile en ideal sonuçlara ulaşmak için parametreler cezalandırma normu  $L_2$ , çözücü veri seti boyutu yüksek olmadığı için "doğrusal", maksimum yineleme sayısı 100, ılık başlama (warm start) değeri ise çözücü değeri doğrusal seçildiği için kullanılmayacak şekilde seçilmiştir. Rassal orman, bu çalışmadaki veri seti ile en iyi sonuçlara ulaşmak için parametreler, bölünme kriteri entropi, maksimum derinlik 15, maksimum özellik sayısını bulmak için gereken fonksiyon logaritma, bir yaprak düğümündeki minimum örnek sayısı 5, bir düğümü bölmek için gereken minimum örnek sayısı 3, oluşturulacak ağaç sayısı 1000, ve işlemci sayısı sınırsız olacak şekilde çalışılmıştır.

Bu çalışmada önerilen derin öğrenme mimarisini olarak, veri sayısının az olması nedeniyle Şekil 7'de verilen bir ESA tasarlanmış ve kullanılmıştır. Literatürde yaygın olan kullanılan diğer mimarilerin genellikle aşırı uyum göstermesi (overfit) ve veriyi ezberlemesi nedeniyle daha az karmaşık bir ağ kullanımının uygun olduğu belirlenmiştir. Çalışma kullanılan model 8 evrişimli katman ve 4 havuz katmandan oluşmaktadır. Kullanılan her evrişimli katman  $3 \times 3$  boyutundadır. Doğrusal aktivasyon fonksiyonu olarak bilinen RELU fonksiyonu tüm evrişimli katmanlara uygulanmış, pozitif girdilerin doğrudan, negatif girdilerin ise 0 olarak çıkması sağlanmıştır. Bu işlem Eş. 21 ile tanımlanabilir [32].

$$f(x) = x^+ = \max(0, x) \quad (21)$$

Aşırı uyumun önüne geçmek ve eğitim performansını arttırmak amacı ile modele iki adet 0,3 oranında bırakma katmanı eklenmiştir. Her parametre için uyarlanabilir öğrenme hızlarının hesabını yapabilen uyarlanabilir moment tahmini olarak bilinen (Adaptive Moment Estimation-ADAM) optimizasyon algoritması öğrenme oranı  $1,0 \times 10^{-5}$  olarak kullanılmıştır. ADAM algoritmasına ait gradyan  $g_t$ ,  $m_t$  ve  $v_t$  ise gradyanların sırası ile ilk ve ikinci momentlerinin tahminleridir [33].



Şekil 7. Kullanılan ESA mimarisini. (The convolutional neural network architecture used.)

$$\begin{aligned} m_t &= \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t &= \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \end{aligned} \quad (22)$$

$\beta_1$  ve  $\beta_2$  hiperparametreleri ile yanlılığı düzeltilmiş birinci moment  $\hat{m}_t$ , ikinci moment  $\hat{v}_t$  ve ADAM güncelleme işlemi yapılır. Bu işlemler Eş. 23 ve Eş. 24'te tanımlandığı gibidir [33].

$$\begin{aligned} \hat{m}_t &= \frac{m_t}{1 - \beta_1^t} \\ \hat{v}_t &= \frac{v_t}{1 - \beta_2^t} \end{aligned} \quad (23)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \quad (24)$$

Çalışmada en sonda modelin başarısının ölçülmesi için, ikili çapraz entropi kayıp fonksiyonu (binary cross entropy loss function) kullanılmıştır. İkili çapraz entropi kayıp fonksiyonu bu çalışmada sinyal verisinin ait olduğu objenin silindirik mayın mı yoksa silindirik kaya mı olduğuna karar vermektedir. Bu entropinin hesaplanması Eş. 25'de verildiği gibidir [34].

$$\mathcal{L}(\hat{\mathbf{y}}, \mathbf{y}) = -\frac{1}{N} \sum_i^N [y_i \log \hat{y}_i + (1 - y_i) \log(1 - \hat{y}_i)] \quad (25)$$

Burada  $\mathcal{L}$  kayıp fonksiyonu değerini,  $y_i$  i'ninci veri için etiket değerini,  $\hat{y}_i$  modelin i'ninci veri için üretmiş olduğu sonucu ve N ise toplam veri sayısını göstermektedir. Bu ESA mimarisi, kayıp fonksiyonu ve etiket değerleri kullanılarak geri yayılım (backpropagation) algoritması ile eğitilmiştir. Şekil 7'de belirtilen ESA mimarisinde kullanılan her bir katmanın özellikleri ve kullanılan parametrelerin detayları Tablo 1'de gösterilmiştir. Bu mimarinin eğitilmesi için

gereken tüm parametrelerin sayısı 53,226,401 olarak hesaplanmıştır.

## 5. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

Zaman serisi verilerinin derin öğrenme algoritmaları ile kullanılabilmesi için yeni bir yöntemin önerilmiştir. Üç farklı matematiksel dönüşüm yönteminden faydalanılarak yeni bir bilgi temsili yaklaşımının önerilmesi ile derin öğrenme algoritmalarının birleştirilmesi sonucunda literatürde rapor edilen en iyi sonuçlar elde edilmiştir. Klasik makine öğrenmesi algoritmalarının performansı ile karşılaştırıldığında önerilen yaklaşım ile literatürde bilinen en yüksek başarımlar elde edilmiştir.

Tablo 2'de bu veri seti üzerinde literatürde daha önce gerçekleştirilen klasik makine öğrenmesi, istatistiksel örüntü tanıma ve öznitelik çıkarma yöntemleri ile elde edilen sonuçlar gösterilmektedir. Literatürdeki çalışmalarda kendi önerdiğimiz başarımlar ölçütlerinden ortak olarak genelde doğruluk değeri rapor edildiği görülmekte ancak kesinlik, geri getirme ve  $F_1$  ölçütü değerlerinin tüm çalışmalarda vermediği tespit edilmiştir. Bu nedenle bu çalışmalardaki başarımlar karşılaştırılması sadece doğruluk değeri üzerinden yapılabilmektedir. Tablo 2'den görüldüğü üzere, çalışmalarda rapor edilen doğruluk değerlerinin en yüksek olduğu çalışmada [15], karmaşık işlemler ve öznitelik çıkarma yöntemleri kullanılarak elde edilen doğruluk değeri %96,25 olarak verilmiştir. Buna en yakın diğer başarımlar ise sırasıyla %95,19 [12] ve %93,26 [11] olarak görülmektedir. Klasik makine öğrenmesi ve istatistiksel örüntü tanıma yöntemleri, sonar sinyallerinin bulunduğu veri setine uygulanmıştır. Karşılaştırmanın daha sağlıklı olarak

**Tablo 2.** ESA mimarisinin veri üzerinde uygulanması sonucu elde edilen ve çalışmada kullanılan parametre sayısı  
(The number of parameters used in the study obtained as a result of applying the CNN architecture on the data)

Katman	Çıkış	Parametre
2 Boyutlu Evrişim	224x224x32	896
2 Boyutlu Evrişim	224x224x32	9248
Maksimum Havuzlama	112x112x32	0
2 Boyutlu Evrişim	112x112x64	18496
2 Boyutlu Evrişim	112x112x64	36928
Maksimum Havuzlama	56x56x64	0
Bırakma Katmanı	56x56x64	0
2 Boyutlu Evrişim	56x56x128	73856
2 Boyutlu Evrişim	56x56x128	147584
2 Boyutlu Evrişim	56x56x128	147584
Maksimum Havuzlama	28x28x128	0
2 Boyutlu Evrişim	28x28x256	295168
2 Boyutlu Evrişim	28x28x256	590080
Bırakma Katmanı	28x28x256	0
Maksimum Havuzlama	14x14x256	0
Düzleme	50176	0
Tam Bağlı YSA	1024	51381248
Tam Bağlı YSA	512	524800
Tam Bağlı YSA	1	513
Toplam Parametre		53,226,401
Eğitilebilir Parametre		53,226,401



**Tablo 3.** Sınıflandırma algoritmaları ile veri setindeki sonar sinyallerinin klasik makine öğrenmesi algoritmaları sonuçları  
(Classical machine learning algorithms results of sonar signals in data set with classification algorithms)

Deney Türü	Doğruluk (%)	Hedef Türü (Mayın/Kaya)	Kesinlik (%)	Geri Getirme (%)	F <sub>1</sub> Ölçütü (%)
DVM (SVM)	92,30	M/K	87,50	100,00	93,33
RO (RF)	86,53	M/K	81,81	96,42	88,51
LR (LR)	90,38	M/K	87,09	96,42	91,51
GNB (G-NB)	67,30	M/K	78,94	53,57	63,82
KA (DT)	75,00	M/K	77,77	75,00	76,35
K-EYK (K-NN)	86,53	M/K	83,87	92,85	88,13
DAA (LDA)	76,92	M/K	78,57	78,57	78,57

**Tablo 4.** Zaman serisi-görüntü dönüşümü metodu ve ESA mimarisine ait en iyi sonuçlar  
(Time series-image transformation method and the best results of the evolutionary nerve network architecture)

Yöntem	Doğruluk (%)	Hedef Türü (Mayın / Kaya)	Kesinlik (%)	Geri Getirme (%)	F <sub>1</sub> Ölçütü (%)
TG (RP)	98,55	M/K	100,00	97,29	98,62
MGA (MTF)	97,10	M/K	97,29	97,29	97,29
GAFA (GADF)	95,65	M/K	94,73	97,29	95,99

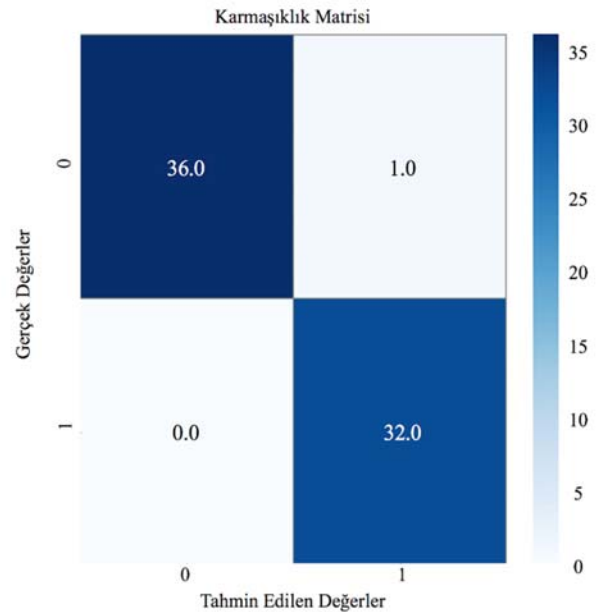
yapılabilmesi için önerilen performans metriklerinin tamamı hesaplanarak rapor edilmiştir. Doğrulama ve model seçimi yöntemi olarak çapraz doğrulama (cross-validation) yöntemi kullanılarak algoritmaların her birinin, en başarılı sonucu veren hiperparametre setinin bulunması sonucu elde edilen performans metrikleri raporlanmıştır. Başarım performanslarının Tablo 3’de verildiği üzere %92,30 ile %67,30 arasında değiştiği ve en başarılı sonuçların DVM ile elde edildiği görülmüştür.


Önerilen yöntemin aynı veri seti üzerinde uygulanması ile Tablo 4’te verilen sonuçlar elde edilmiştir. Modelin eğitilmesi ve sonuçların elde edilmesi için ESA’nın bir katmandaki nöron sayısı, evrişim katmanı parametreleri, katman sayısı, aktivasyon fonksiyonu türü, öğrenme oranı ve katmanlar için ilkleme yöntemleri, hiperparametre olarak farklı kombinasyonlarda kullanılarak çapraz doğrulama algoritmaları ile başarımları ölçülmüştür. En iyi sonucu veren hiperparametreler kullanılarak aşırım uyum göstermeyen (overfit) modellerin sonucu raporlanmıştır.

ESA mimarisi, veri dönüşümleri tamamlandıktan sonra her bir dönüşüm işlemi için ayrı ayrı eğitilmiştir. Eğitim için ADAM optimizasyon algoritması öğrenme oranı  $1e-5$  olarak seçilerek 100 devir (epoch) boyunca 5 kat çapraz doğrulama ile yineleme (iterasyon) yapılmıştır. Yineleme boyunca öğrenme oranı da belirli bir oranda azaltılarak kayıp fonksiyonunda minimum değere ulaşılmaya çalışılmıştır.


TG, MGA ve GAFA dönüşümleri sonrası eğitilen ESA modelleri ile elde edilen başarım oranları sırasıyla %98,55, %97,10 ve %95,65 olarak elde edilmiştir.

Elde edilen başarım metrikleri ışığında, tekrarlanma grafiği yöntemi ile elde edilen görüntüler üzerinden eğitilen ESA için %98,55 doğruluk ile en başarılı sonuçların elde edildiği ve bu sonucu takiben %97,10 ve %95,65 doğruluk oranlarının sırasıyla MGA ve GAFA yöntemleri ile elde edildiği görülmektedir. Tablo 4’te elde edilen sonuçlar için karmaşıklık matrisleri Şekil 8, 9 ve 10’da verilmektedir.

**Şekil 8.** Tekrarlanma grafiğine ait karmaşıklık matrisi  
(Confusion matrix related to recurrence plot)



**Şekil 9.** Markov geçiş alanına ait karmaşıklık matrisi.  
(Confusion matrix related to markov transition field.)



**Şekil 10.** Gramian açısıl alana ait karmaşıklık matrisi.  
(Confusion matrix related to gramian angular field)

Gerçekleştirilen her bir deneyin, model eğitme süreleri 10 defa tekrar edilerek ölçülmüştür. Deneylerin tamamı Intel I7 7700K işlemcili, 32 GB RAM'e sahip bir bilgisayar üzerinde gerçekleştirilmiştir.

ESA modelinin eğitilmesi için NVidia 2080 TI marka ve modellenmiş bir GPU kullanılmıştır. Elde edilen ortalama eğitim süreleri ve standart sapma değerleri Tablo 5'de sunulmuştur.

**Tablo 5.** Klasik makine öğrenmesi algoritmaları ve ESA mimarisi ile yapılan çalışmalara ait çalışma süreleri  
(Running times of studies with classical machine learning algorithms and CNN architecture)

Deney Türü	Çalışma Süresi
DVM (SVM)	$0,10 s \pm 150$ ms
RO (RF)	$6,82 s \pm 500$ ms
LR (LR)	$1,27 s \pm 151$ ms
GNB (G-NB)	$0,92 s \pm 15$ ms
KA (DT)	$0,28 s \pm 18$ ms
K-EYK (K-NN)	$0,44 s \pm 2$ ms
ESA-10 kat çapraz doğrulama (CNN)	$30,590s \pm 17$ s

## 5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada; zaman serisi türündeki verilerin derin öğrenme algoritmaları ile kullanılabilmesi için yeni bir yöntem önerilmiştir. Üç farklı matematiksel dönüşüm yönteminden faydalanılarak (MGA, TG, GAA) yenilikçi bir bilgi temsil yaklaşımı ile derin öğrenme algoritmalarının ilk kez bir sistem altında birleştirilmesi sağlanarak yüksek performanslı ve başarılı bir sistem geliştirmiştir. İkili sınıflandırma probleminin çözümü için, önerilen sistematik yaklaşımın performansı; doğruluk, geri getirme, kesinlik ve  $F_1$  ölçütü metrikleri ile literatürde iyi bilinen ve çok zor bir veri seti olan sonar veri seti kullanılarak, klasik makine öğrenmesi algoritmaları ile karşılaştırılmış ve önerilen yaklaşımın üstünlüğü doğrulanmıştır. Ayrıca, bu çalışmada kullanılan sonar veri seti üzerinde literatürde daha önce yürütülen çalışmalar da incelenerek, elde edilen sonuçlar değerlendirildiğinde önerilen sistematik yaklaşımın ile bilinen en yüksek skorların elde edildiği belirlenmiştir. TG, MGA ve GAA dönüşümleri sonrası eğitilen ESA modelleri ile elde edilen başarı oranları sırasıyla %98,55, %97,10 ve %95,65 olarak hesaplanmıştır. Hesaplanan başarı metrikleri ışığında, tekrarlanma grafiği yöntemi ile üretilen görüntüler üzerinden eğitilmiş ESA modeli için %98,55 doğruluk, %100 kesinlik, %97,29 geri getirme ve %98,62  $F_1$  ölçütü değerleri ile en başarılı sonuçlara ulaşıldığı görülmektedir.

Literatürdeki yaklaşımlar ve yöntemler incelendiğinde boyut azaltma yaklaşımlarının kullanıldığı yöntemlerin daha başarılı sonuçlar verdiği görülmektedir. Ön işleme aşamasında kullanılan bu boyut düşürme algoritmaları ve diğer öznelik çıkarma yöntemleri, ikili sınıflandırma probleminin çözümünde kullanılarak makine öğrenmesi ve istatistiksel örüntü tanıma yöntemleri için girdi olarak kullanılmaktadır. Yine literatürde görüldüğü üzere, bu problemin çözümünde oldukça karmaşık özneliklerin ve matematiksel dönüşüm yöntemlerinin uygulandığı ve sınıflandırma algoritmaları ile birlikte kullanıldığı tespit edilmektedir.

TG ve MGA dönüşümü sayma tabanlı olasılıksal bir matematiksel dönüşüm türüdür ancak GAFA ve GATA yöntemleri zamansal ve uzaysal korelasyonu dikkate alan bir dönüşüm metodudur. Bu veri seti için sayma tabanlı olasılıksal görüntü dönüşümlerinin daha iyi sonuç verdiği yürütülen deneysel çalışmalar ile tespit edilmiştir [35]. Önerilen yöntemin TG, GAFA ve MGA dönüşümleri sayesinde klasik yöntemlerden daha etkin bir öznelik çıkarıcı olarak kullanılabilirliği görülmektedir. Bu hipotez daha farklı ve başarımı zor birçok veri seti ile de gelecekteki çalışmalarda test edilerek doğrulanacaktır.

Bu çalışmada açıklanan ve kullanılan yöntemin zaman serisinden görüntüye dönüştürülmesi özelinde bir dezavantajı olarak, dönüşüm metodu olarak kullanılan TG, GAFA ve MGA'nın sonucunda verinin matrisler olarak ifade edilmesinden dolayı, bu matrislerin hesaplamasında zaman serisinin uzunluğunun büyük olduğu durumlarda, dönüşüm sonucunun da elde edilmesi uzun olabilmektedir. Daha gelişmiş donanımlar ile daha kısa sürede tamamlanabilecek bu hesaplamalar, 60 frekans bandından oluşan veri seti kullanıldığında, Intel I7 7700K işlemcili bir bilgisayarda, ortalama olarak TG için 523 ms  $\pm$  15 ms, MGA için 892 ms  $\pm$  25 ms ve GAFA için 1.21 ms  $\pm$  5 ms sürmektedir.

Müteakip çalışmalarda farklı derin öğrenme mimarilerinin bu dönüşümler ile birlikte kullanılarak performanslarının incelenmesi sağlanacaktır. Ayrıca tekrarlama grafiği yönteminin iki farklı türü olan çapraz tekrarlama grafiği (cross repetition plot) ve ortak tekrarlama grafiği (joint repetition plot) yöntemlerinin de sınıflandırma problemlerinde başarımının ölçülmesi planlanmaktadır.

#### TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışmanın gerçekleşmesinde alt yapı ve donanım desteği sağlayan Türkiye Cumhuriyeti Cumhurbaşkanlığı Dijital Dönüşüm Ofisi, Büyük Veri ve Yapay Zekâ Uygulamaları Daire Başkanlığına teşekkür ederiz. Bu çalışmaya [35] numaralı referansta belirtilen ICENTE'2020 konferansında sunulan ve tam metni yayımlanan bildirinin genişletilmiş ve Türkçeleştirilmiş biçimidir.

#### KAYNAKLAR (REFERENCES)

1. Waite A.D., Sonar for Practising Engineers. Wiley, West Sussex, İngiltere, 2002.
2. Jing L., The Principle of Side Scan Sonar and Its Application in The Detection Of Suspended Submarine Pipeline Treatment, Materials Science and Engineering, 439, 2018.
3. Lucieer V.L., Object-Oriented Classification Of Sidescan Sonar Data For Mapping Benthic Marine Habitats, International Journal of Remote Sensing, 29 (3), 905–921, 2018.
4. Burguera A., Oliver G., High-Resolution Underwater Mapping Using Side-Scan Sonar, PLOS ONE. 11 (1), 2016.
5. Flowers H.J., Hightower J.E., A Novel Approach to Surveying Sturgeon Using Side-Scan Sonar and Occupancy Modeling, Marine and Coastal Fisheries. 5 (1), 211–223, 2013.
6. Çelebi A.T., Güllü M.K., Ertürk S., Mine Detection in Side Scan Sonar Images Using Markov Random Fields With Brightness Compensation, IEEE 19th Signal Processing and Communications Applications Conference (SIU), 916–919, 2011.
7. Huebner C.S., Evaluation Of Side-Scan Sonar Performance For The Detection Of Naval Mines, Target And Background Signatures IV, SPIE, 10794, 158–166, 2018.
8. Verleysen M., François D., The Curse of Dimensionality in Data Mining and Time Series Prediction. Lecture Notes in Computer Science, 3512 (06), 758–770, 2005.
9. Gorman R.P., Sejnowski T.J., Analysis of Hidden Units in a Layered Network Trained to Classify Sonar Targets. Neural Networks., 1 (1), 75–89, 1988.
10. Pamaja V., Rajendran V., Vijayalakshmi P., 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), 2020.
11. Erkmén B., Yıldırım T., Improving Classification Performance Of Sonar Targets By Applying General Regression Neural Network With PCA, Expert Systems with Applications, 35 (1-2), 472–475, 2008.
12. Bakbak P.O., Peker M., Classification Of Sonar Echo Signals in Their Reduced Sparse Forms Using Complex-Valued Wavelet Neural Network, Neural Computing and Applications (Neural Comput Appl), 32 (1), 2020.
13. Hossin M., Mahudin F., Din I., Mat A.R., Analysis of Nine Instance-Based Genetic Algorithm Classifiers Using Small Datasets. Journal of Telecommunication, Electronic and Computer Engineering, 9, 3–11, 2017.
14. Novakovic J., Using Information Gain Attribute Evaluation to Classify Sonar Targets., Telecommunications forum (TELFOR), 8, 5-11, 2009.
15. Fong S., Deb S., Wong R., Underwater Sonar Signals Recognition by Incremental Data Stream Mining with Conflict Analysis, International Journal of Distributed Sensor Networks, 10 (5), 2014.
16. Hong X., Zhang J., Guan S.U., Incremental Maximum Gaussian Mixture Partition For Classification., 2nd Joint International Information Technology, Mechanical and Electronic Engineering Conference (JIMEC 2017), 62, 2017.
17. Shang T., Xia X., Zheng J., MIME-KNN: Improve KNN Classifier Performance Include Classification Accuracy and Time Consumption, DEStech Transactions on Computer Science and Engineering, 2018.
18. Doğan Y., Improvement of Self-Repeating Deep Neural Networks With Feature Selection Methods and Their Use In Automatic Identification System Data Considered as Time Series, Journal of the Faculty of Engineering and Architecture of Gazi University, 35 (4), 1897-1912, 2020.

19. Kasım Ö., Kuzucuoğlu A., Detection and classification of leukocyte cells from smear image, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 30 (1), 95-109, 2015.
20. Aktaş, A., Doğan, B., Demir, Ö., Tactile Parquet Surface Detection With Deep Learning Methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (3), 1685-1700, 2020.
21. Yun X., Goodacre R., On Splitting Training and Validation Set: A Comparative Study of Cross-Validation, Bootstrap and Systematic Sampling for Estimating the Generalization Performance of Supervised Learning, *Journal of Analysis and Testing*, 2 (3), 249-62, 2018.
22. Wang Z., Oates T., Imaging Time-Series to Improve Classification and Imputation, *Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence (IJCAI)*, Temmuz 2015.
23. Wang Z., Oates T., Spatially Encoding Temporal Correlations to Classify Temporal Data Using Convolutional Neural Networks, *Journal of Computer and Systems Sciences*, 2015.
24. Eckmann J.P., Kamphorst S.O., Ruelle D., Recurrence Plots of Dynamical Systems, *Euro-Physics Letters (EPL)*. 4 (9), 973-977, 1987.
25. Tang, Z., Zeng, X., Guo, Z., & Song, M., Malware Traffic Classification Based on Recurrence Plots and Deep Neural Networks Quantification Analysis. *Int. J. Netw. Secur.*, 22, 449-459, 2020.
26. Cortes C., Vapnik V., Support-vector Networks, *Machine Learning*, 20 (3), 273-297, 1995.
27. Benkercha R., Moulahoum S., Fault Detection And Diagnosis Based On C4.5 Decision Tree Algorithm For Grid Connected PV System, *Solar Energy*, 173, 610-634, 2018.
28. Zhang S., Cheng D., Deng Z., Zong M., Deng X., A novel KNN Algorithm With Data-Driven K Parameter Computation, *Pattern Recognition Letters*, 109, 44-54, 2018.
29. Raschka S., Mirjalili V., *Python Machine Learning*, 2nd Edition, A.B.D., 2017.
30. Wen J., Fang X., Cui J., Fei L., Yan K., Yan C., Xu Y., Robust Sparse Linear Discriminant Analysis, *IEEE Transactions on Circuits and Systems for Video Technology*, 29 (2), 390-403, 2018.
31. Zhu C., Idemudia C.U., Feng W., Improved Logistic Regression Model For Diabetes Prediction By Integrating PCA and K-Means Techniques, *Informatics in Medicine Unlocked*, 17, 2019.
32. Banerjee C., Mukherjee T., Pasiliao E., The Multi-phase ReLU Activation Function *Annals of Statistics*, *Proceedings of the 2020 ACM Southeast Conference (ACM SE '20)*, Tampa FL USA, 239-242, Nisan 2020.
33. Taqi A. M., Awad A., Al-Azzo F., Milanova M., The Impact of Multi-Optimizers and Data Augmentation on TensorFlow Convolutional Neural Network Performance, *IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*, Miami, FL, 140-145, 2018.
34. Ruby A.U., Theerthagiri P., Jacob I.J., Vamsidhar Y., Binary Cross Entropy With Deep Learning Technique For Image Classification, *International Journal of Advanced Trends in Computer Science and Engineering*, 9 (4), 5393-5397, 2020.
35. A. Civrizoğlu Buz, M.U. Demirezen, U. Yavanoğlu., A Novel Approach and Application of Time Series to Image Transformation Methods on Classification of Underwater Objects, in *Proceedings of the 4th International Conference on Engineering Technologies (ICENTE'20)*. 19-21 Kasım 2020, Konya, Türkiye, [https://icente.selcuk.edu.tr/uploads/files2/ICENTE20\\_ProceedingsBook\\_v1.pdf](https://icente.selcuk.edu.tr/uploads/files2/ICENTE20_ProceedingsBook_v1.pdf), Erişim Tarihi: 15 Ocak. 2021.

