

**GNSS KARIŐTIRMA TİPİ SINIFLANDIRMADA MAKİNE
ÖĐRENMESİ YAKLAŐIMI**

**MACHINE LEARNING APPROACH IN GNSS JAMMING
TYPE CLASSIFICATION**

MERT GÖKDUMAN

DR. ÖĐR. ÜYESİ YAKUP ÖZKAZANÇ

Tez DanıŐmanı

Hacettepe Üniversitesi
Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin
Elektrik ve Elektronik Mühendisliđi Anabilim Dalı için Öngördüğü
YÜKSEK LİSANS TEZİ
olarak hazırlanmıŐtır.

2022

ÖZET

GNSS KARIŞTIRMA TİPİ SINIFLANDIRMADA MAKİNE ÖĞRENMESİ YAKLAŞIMI

MERT GÖKDUMAN

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği Bölümü

Tez Danışmanı: Dr. Öğr. Üyesi Yakup ÖZKAZANÇ

Haziran 2022, 81 Sayfa

GNSS sinyalleri günümüzde uydu takımına bağlı olarak konumun, zamanın ve hızın tespit edilmesinde değerlendirilen sinyallerdir. Askeri ve sivil unsurların birçoğu ilgili verileri elde edebilmek için GNSS yapısında olan GPS, GLONASS, BEIDOU gibi sistemlerden gelen bu sinyalleri kullanır. Bu bilgi insanlı/insansız tüm platformların ulaşmak istediği hedefe en düşük sapmayla en doğru şekilde ulaşmasını amaçlar. Ancak, bu sinyallerin karıştırılması ve kullanıcının bu sinyalden elde etmesi gereken veriye ulaşmasının engellenmesi yaklaşımı günümüzde sıkça kullanılan yaklaşımlardandır. Karıştırıcıların müdahalesiyle platformlar ve sistemler konum veya hız kaybederek etkisiz hale gelebilmektedir. Unsurların ele geçirilmesi, kırılma uğraması, kaybolması, istenen şekilde görev icra edememesi gibi durumlar karıştırma faaliyetlerinin ana çıktılardan biridir. Kullanıcı karıştırmanın bahsedilen bu olumsuz etkilerinden kurtulabilmek amacıyla karıştırıcıyı tespit etmeyi ve etkisini azaltıcı bazı yaklaşımlar sergilemeyi hedefler.

Karıştırıcıların belirli türleri bulunmaktadır. Bu türlerin birbirinden ve karıştırma olmayan durumdan ayrılabilmesi, karıştırıcı etkisinin azaltılmasında kritik öneme sahip bir durum olarak değerlendirilmektedir. Sınıflandırmanın doğru yapılabilmesi negatif etkilerin azaltıl-

masına dair en doğru çözümün uygulanabilmesine imkan sağlar. Bu sınıflandırmanın yüksek hızlarda yapılabilmesi insan eliyle mümkün olamamaktadır. Bu nedenle ve en doğru sınıflandırmayı elde edebilmek amacıyla bu sınıflandırma problemlerinin çözümünde makine öğrenmesi yaklaşımlarından birinin ya da birkaçının kullanılması birçok farklı çalışmada ele alınmıştır.

GNSS karıştırıcıların tespit edilmesini ve karıştırıcı türünün doğru sınıflandırılmasını amaçlayan bu çalışmada, AM, FM, NB ve Chirp karıştırıcı olarak dört durum ve karıştırıcı olmayan durum olmak üzere beş durum belirlenmiş, her durum için 10000 adet sinyal olarak toplamda 50000 adet sinyal üretilmiştir. Oluşturulan sinyaller belirli gürültü ve karıştırma oranlarına bağlı olarak daha gerçekçi bir hale getirilmiştir.

Elde edilen sinyaller öncelikle doğrudan ham veri olarak, sonrasında kısa zamanlı Fourier dönüşüm (STFT) ile elde edilen öznitelikler kullanılarak ve ardından Wigner-Ville Dağılımı ile elde edilen öznitelikler kullanılarak makine öğrenmesi modellerine girdi olarak sağlanmıştır. Öznitelik çıkarılarak yürütülen çalışmalarda tercih edilen STFT ve Wigner-Ville analiz yöntemlerinden hangisinin daha iyi performans sergilediği ve öznitelik çıkarılmadan doğrudan ham verilerle yapılan çalışmalarda elde edilen performansın öznitelik çıkarılarak yürütülen çalışmalara kıyasla nasıl bir sonuç sağladığı analiz edilmiştir.

Ham veri ve zaman-frekans analizleriyle elde edilen öznitelikler CNN, SVM, RF, MLP ve NN olarak belirlenen beş ayrı makine öğrenmesi modeline verilmiş ve öğrenme performansları elde edilmiştir. Tüm verilerle elde edilen sonuçlar AM, FM, NB, Chirp ve NJ olarak etiketlenmiştir. NJ durumu karıştırmanın olmadığı durumu ifade ederken, AM, FM, Chirp ve NB durumları ilgili karıştırıcıların varlığının tespit edildiği durumları ifade etmektedir.

Tercih edilen makine öğrenmesi modellerinden en iyi performansın STFT ile elde edilen özniteliklerin kullanılmasıyla yürütülen CNN öğrenme modeli sonucunda sağlanabildiği ve sınıflandırma performansının %98.5 olduğu gözlenmiştir.

Anahtar Kelimeler: GNSS, GPS, Karıştırma, Yapay Zeka, Derin Öğrenme, Makine Öğrenmesi

ABSTRACT

MACHINE LEARNING APPROACH IN GNSS JAMMING TYPE CLASSIFICATION

MERT GÖKDUMAN

Master of Science, Department of Electrical and Electronics Engineering

Supervisor: Dr. Lecturer Yakup ÖZKAZANÇ

June 2022, 81 Pages

Today, GNSS signals are signals that are evaluated in determining position, time and speed depending on satellite sets. In order to obtain relevant data many of the military and civilian elements use these signals from systems such as GPS, GLONASS, BEIDOU, which are parts of the GNSS system. This information aims to ensure that all manned/unmanned platforms reach the target they want to achieve in the most accurate way with the lowest deviation. However, the approach of jamming these signals and preventing from accessing the data the user they need to obtain from this signal is one of the approaches frequently used today. Platforms and systems can be adjusted to their position or speed and they can be neutralized by losing their consciousness about it with the intervention of jamming. Situations such as seizing, breaking, disappearing, and inability to perform tasks as desired are among the main outputs of jamming activities. In order to get rid of these negative effects of jamming, the user aims to identify the mixer and show some approaches to reduce its effect.

There are certain types of jamming. The separation of these cases from each other and from the state without jamming is considered a critical situation in reducing the jamming effect. The correct classification enables the most accurate solution to be applied to reduce negative effects of jamming. It is not possible to make this classification at high speeds by human

hands. For this reason, using one or more of the machine learning approaches in solving these classification problems in order to obtain the most accurate classification, has been discussed in many different studies.

There are four cases as AM, FM, NB and Chirp jamming and fifth situation are determined as a case without jamming In this study which aims to detect GNSS jamming and to classify the jamming types correctly. We had a totally of 50000 signals are produced as 10000 signals for each cases. The generated signals are made more realist depending on certain noise ratios and mixing ratios.

The obtained signals are provided as input to the machine learning models firstly as raw data directly, then by using the features extraction by short-time Fourier transform (STFT), and then by using the features extraction with the Wigner-Ville Distribution. It has been analyzed which of the preferred STFT and Wigner-Ville analysis methods performs better in feature extraction processing and how does the performance obtained in studies conducted directly with raw data without feature extraction compare to the studies conducted by feature extraction.

Raw data and features extracted by time-frequency analyzes were given to five different machine learning models determined as CNN, SVM, RF, MLP and NN and learning performances were obtained. Results with all data are labeled as AM, FM, NB, Chirp, and NJ cases. The NJ case represent the absence of jamming, while the AM, FM, Chirp and NB cases represent the cases in which the presence of the relevant jamming is detected.

It has been observed that the best performance from the preferred machine learning models can be achieved as a result of the CNN learning model carried out by using the features extracted with STFT, and the classification performance is %98.5.

Keywords: GNSS, GPS, Jamming, Artificial Intelligence, Deep Learning, Machine Learning

TEŐEKKÜR

Bu tezin ortaya ıkması s¼recinde geliŐime ihtiya duyduėum her anda sabırla bana destek olan, her yorumuyla hem m¼hendisliėe hem iŐ d¼nyasına hem de akademiye dair vizyonunun geliŐmesinde ciddi katkısı olan kıymetli danıŐmanım Dr. Öğr. Üyesi Yakup ÖZKAN-ZANÇ hocama,

alıŐma hayatımda sahip olduėum en büyük imkanlardan biri olan, her zaman güvenini hissettiėim, geliŐimim için destekleriyle bana büyük imkan saėlayan ve birlikte olmaktan onur duyduėum büyüėum, yöneticim Murat İKİNCİ'ye,

Beni yetiŐtirirken her türlü fedakarlıėı ve özveriyi sürekli olarak gösteren, her zaman desteklerini en yakınımda hissettiėim, geldiėim noktanın asıl mimarları olan annem Zuhal GÖKDUMAN'a ve babam Erdal GÖKDUMAN'a,

Akademik hayatımın devam etmesinde büyük katkısı olan, motivasyonumu her kaybettiėimde desteėiyle beni teŐvik ederek hep yanımda olan kıymetli eŐim Sevin GÖKDUMAN'a sonsuz sevgi ve teŐekk¼lerimi sunarım.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ÇİZELGELER	ix
ŞEKİLLER	xi
KISALTMALAR	xiii
1 GİRİŞ	1
1.1 Makine Öğrenmesi Yöntemleriyle Karıştırma Tespiti ve Sınıflandırılması	3
1.2 Tezin Amacı	5
2 GNSS SİSTEMLERİ	7
2.1 GNSS Kavramı	7
2.1.1 GPS Sistemi	9
2.1.1.1 GPS Sinyalinin Yapısı	10
2.1.2 GLONASS Sistemi	11
2.1.2.1 Uzay Segmenti	12
2.1.2.2 Kontrol Segmenti	13
2.1.2.3 Kullanıcı Segmenti	14
2.1.3 GALILEO Sistemi	15
2.1.4 BEIDOU Sistemi	16
3 GNSS KARIŞTIRMA VE ANALİZ YÖNTEMLERİ	19
3.1 GNSS Karıştırıcı Sistemler	19
3.1.1 AM Karıştırıcı	19
3.1.2 FM Karıştırıcı	20
3.1.3 NB Karıştırıcı	20
3.1.4 Chirp Karıştırıcı	20
3.2 Gürültü	21

3.3	Sinyal İşleme Teknikleri	22
3.3.1	Kısa Zamanlı Fourier Dönüşümü (STFT)	22
3.3.2	Wigner-Ville Dağılımı	26
3.4	Makine Öğrenmesi Yöntemleri	29
3.4.1	Rastgele Orman	29
3.4.2	Destek Vektör Makineleri	30
3.4.3	Çok Katmanlı Algılayıcı	31
3.4.4	Sinir Ağları	33
3.4.4.1	Evrişimli Sinir Ağları	34
3.4.5	Öznitelik Çıkarımı	36
3.4.6	Veriyi ve Öznitelikleri Sınıflandırma Algoritmalarına Hazırlama İş- lemleri	37
3.4.6.1	Veriyi ve Öznitelikleri Ayırma Yaklaşımı	37
3.4.6.2	Normalizasyon	38
3.4.6.3	Hiperparametre Seçimi	39
3.4.6.3.1	Izgara Arama Yöntemi	39
3.4.7	Karışıklık Matrisi	40
4	GNSS KARIŞTIRMA TİPİ SINIFLANDIRMA ÇALIŞMALARI	43
4.1	Sinyallerin Oluşturulması	43
4.1.1	Karıştırıcı ve Gürültü İçermeyen GNSS Sinyali	44
4.1.2	Karıştırıcı İçermeyen Ancak Gürültü İçeren GNSS Sinyali	46
4.1.3	AM Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyali	47
4.1.4	AM Karıştırıcı ve Gürültü İçeren GNSS Sinyali	48
4.1.5	FM Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyali	49
4.1.6	FM Karıştırıcı ve Gürültü İçeren GNSS Sinyali	50
4.1.7	Chirp Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyali	51
4.1.8	Chirp Karıştırıcı ve Gürültü İçeren GNSS Sinyali	52
4.1.9	NB Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyali	54
4.1.10	NB Karıştırıcı ve Gürültü İçeren GNSS Sinyali	56
4.2	Öznitelik Çıkarımı	57
4.2.1	Kısa Zamanlı Fourier Dönüşüm - STFT	57
4.2.2	Wigner-Ville Dağılımı	58

4.3	Karıştırıcı Sınıflandırma Yöntemleri	61
4.3.1	Rastgele Orman Yöntemi	62
4.3.2	Destek Vektör Makineleri Yöntemi	62
4.3.3	Çok Katmanlı Algılayıcı Yöntemi	62
4.3.4	Sinir Ağları Yöntemi	63
4.3.5	CNN	63
4.4	Karıştırıcı Sınıflandırma Analizleri	63
4.4.1	Ham Sinyalin Kullanılmasıyla Sınıflandırma Performansı	63
4.4.2	STFT Uygulanarak Çıkarılan Özniteliklerin Kullanılmasıyla Sınıflandırma Performansı	66
4.4.3	Wigner-Ville Uygulanarak Çıkarılan Öznitelikleri Sınıflandırması Performansı	70
4.4.4	Algoritmaların Süre Performans Analizlerinin Karşılaştırılması	76
5	SONUÇLAR	78

ÇİZELGELER

Çizelge 2.1.1	GLONASS Uydularının Yörünge Karakteristiklerinin GPS Uydularıyla Karşılaştırılma Çizelgesi	13
Çizelge 2.1.2	GALILEO Sisteminin GPS Uydularıyla Karşılaştırılma Çizelgesi	16
Çizelge 2.1.3	BEIDOU Taşıyıcı Frekanslar Çizelgesi	18
Çizelge 4.4.1	Ham Veri Seti Performans Analiz Çizelgesi	64
Çizelge 4.4.2	STFT Veri Seti Doğruluk Performansı Analiz Çizelgesi	66
Çizelge 4.4.3	STFT Veri Seti Performans Analiz Çizelgesi	68
Çizelge 4.4.4	Wigner-Ville Veri Seti Doğruluk Performansı Analiz Çizelgesi .	71
Çizelge 4.4.5	Wigner-Ville Veri Seti Performans Analiz Çizelgesi	72
Çizelge 4.4.6	Performans Analiz Çizelgesi	75
Çizelge 4.4.7	Algoritma Süre Performans Analiz Çizelgesi	76

ŞEKİLLER

Şekil 2.1.1	Uydu Tabanlı Konumlama Sistemi Prensibi [2]	7
Şekil 2.1.2	GPS Sistemini Temel Yaklaşımı [10]	10
Şekil 2.1.3	(a) Sinusoidal Taşıyıcı Frekans, (b) Dijital Kod [10]	11
Şekil 2.1.4	C/A Kod - P Kod – Navigasyon Mesajı ve Taşıyıcı Sinyallerin Modülasyonu [12]	12
Şekil 2.1.5	GLONASS Uydularının 17 Mart 1999 Tarihindeki Nihai Yerleşim Gösterimi [14]	14
Şekil 2.1.6	Bölgesel BEIDOU 2 ya da COMPASS Olarak İfade Edilen Gelişmiş Sistemdeki Uyduların Yörünge Hareketleri [18]	17
Şekil 3.2.1	Esas Sinyal, Gürültü ve Gürültü Eklenmiş Bozulmuş Sinyal Gösterimi [23]	22
Şekil 3.3.1	Ayrık ve Sürekli Sinyallerin Gösterimi [27]	24
Şekil 3.3.2	Kısa Zamanlı Fourier Dönüşüm Uygulaması Gösterimi [30]	25
Şekil 3.3.3	Başlangıç Frekansı 0.1 ve Bitiş Frekansı 0.4 Olan Doğrusal Bir FM Sinyali Üzerinde Farklı Boyutlardaki Pencerelemler ile Kısa Zamanlı Fourier Dönüşümünün Etkileri [29]	25
Şekil 3.3.4	Çapraz Terimlerin Etkisinin Azaltılması İçin Yumuşatılmış Wigner-Ville uygulaması Örneği [33]	27
Şekil 3.4.1	Rastgele Orman Şeması [35]	30
Şekil 3.4.2	Destek Vektör Makineleri Çalışma Prensibi [37]	31
Şekil 3.4.3	Destek Vektör Makinelerinde Çekirdeklenme Yöntemiyle Boyut Artırma [39]	31
Şekil 3.4.4	Tek Katmanlı Algılayıcılar [40]	32
Şekil 3.4.5	XOR Doğruluk Tablosu [41]	32
Şekil 3.4.6	Çok Katmanlı Algılayıcı Modeli [40]	33
Şekil 3.4.7	Bir Sinir Ağı Gösterimi [44]	34
Şekil 3.4.8	Yüz Tanıma Amacıyla Tasarlanmış Olan Bir Evrişimli Sinir Ağı'nın Katmanlarında Yer Alan Filtreleme Örneği [45]	35

Şekil 3.4.9	32X32X3 Bağlantıya Sahip Bir Evrişimli Sinir Ağı Gösterimi [45]	36
Şekil 3.4.10	Matris Filtrelerden Örnek Gösterim [47]	36
Şekil 3.4.11	Karışıklık Matrisi Tablosu [53]	40
Şekil 4.1.1	Karıştırıcı ve Gürültü İçermeyen GNSS Sinyal Analizleri	44
Şekil 4.1.2	Karıştırıcı İçermeyen Ancak Gürültü İçeren GNSS Sinyal Analizleri	46
Şekil 4.1.3	AM Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyal Analizleri	47
Şekil 4.1.4	AM Karıştırıcı ve Gürültü İçeren GNSS Sinyal Analizleri	48
Şekil 4.1.5	FM Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyal Analizleri	49
Şekil 4.1.6	FM Karıştırıcı ve Gürültü İçeren GNSS Sinyal Analizleri	50
Şekil 4.1.7	Chirp Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyal Analizleri	52
Şekil 4.1.8	Chirp Karıştırıcı ve Gürültü İçeren GNSS Sinyal Analizleri	53
Şekil 4.1.9	NB Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyal Analizleri	54
Şekil 4.1.10	NB Karıştırıcı ve Gürültü İçeren GNSS Sinyal Analizleri	56
Şekil 4.2.1	Karıştırıcı İçermeyen GNSS Sinyali Spektral Analizi	59
Şekil 4.2.2	AM Karıştırıcı İçeren GNSS Sinyali Spektral Analizi	59
Şekil 4.2.3	FM Karıştırıcı İçeren GNSS Sinyali Spektral Analizi	60
Şekil 4.2.4	Chirp Karıştırıcı İçeren GNSS Sinyali Spektral Analizi	60
Şekil 4.2.5	NB Karıştırıcı İçeren GNSS Sinyali Spektral Analizi	61
Şekil 4.4.1	Ham Veri Seti Karışıklık Matrisi	65
Şekil 4.4.2	STFT Veri Seti Karmaşıklık Matrisleri	69
Şekil 4.4.3	Wigner-Ville Veri Seti Karmaşıklık Matrisleri	74

KISALTMALAR

AM	Amplitude Modulation (Genlik Modülasyonu)
AWGN	Additive White Gaussian Noise (Eklemeli Beyaz Gaus Gürültü)
BOC	Binary Offset Carrier (İkili Ofset Taşıyıcı)
CEP	Circular Error Probability (Dairesel Hata Olasılığı)
CRPA	Controlled Reception Pattern Antenna
CN0	Carrier to Noise Ratio (Taşıyıcı Sinyal Gücünün Gürültü Gücüne Oranı)
CDMA	Code Division Multiple Access (Kod Bölmeli Çoklu Erişim)
CNN	Convolutional Neural Network (Evrimsimli Sinir Ağları)
DFT	Discrete Fourier Transform (Ayrık Fourier Dönüşümü)
FFT	Fast Fourier Transform (Hızlı Fourier Dönüşümü)
FM	Frequency Modulation (Frekans Modülasyonu)
GNSS	Global Navigation Satellite Systems (Küresel Uydu Seyrüsefer Sistemi)
GPS	Global Positioning Systems (Küresel Konumlama Sistemi)
INS	Inertial Measurement System (Ataletsel Navigasyon Sistemi)
JSR	Jamming to Signal Ratio (Karıştırmacı Gücünün Sinyal Gücüne Oranı)
KKS	Global Navigation Satellite Systems (Küresel Konumlama Sistemi)
LDA	Linear Discriminant Analysis (Lineer Diskriminant Analizi)
LEO	Low Earth Orbit (Alçak Dünya Yörüngesi)
LNA	Low Noise Amplifier (Düşük Gürültülü Amplifikatör)
MEO	Medium Earth Orbit (Orta Dünya Yörüngesi)
MLP	Multilayer Perceptron (Çok Katmanlı Algılayıcı)
NB	Narrow Band (Dar Bant)
NN	Neural Networks (Sinir Ağları)
PCA	Principal Component Analysis (Temel Bileşenler Analizi)
PRN	Pulse Repetition Number (Darbe Tekrar Sayısı)
PSD	Power Spectral Density (Güç Spektral Yoğunluğu)
RF	Random Forest (Rastgele Orman)
SNR	Signal to Noise Ratio (Sinyal Gücünün Gürültü Gücüne Oranı)
STFT	Short Time Fourier Transform (Kısa Zamanlı Fourier Dönüşümü)
SVM	Support Vector Machine (Destek Vektör Makineleri)
WB	Wide Band (Geniş Bant)

1. GİRİŞ

İnsanoğlunun uzaya erişimiyle uzayda konuşlandırılan uydu ve anten sistemlerinin teknolojik bir üstünlük olarak kullanılması önemli bir kazanım olarak görülmüştür. Yeryüzünde kısıtlı limitlerle aşılmaya çalışılan problemlerin birçoğunun uzay sistemleri aracılığıyla daha çözülebilir hale gelmesi bu alanda yapılan çalışmaların ve yatırımların artmasına yol açmıştır. Özellikle konum tespiti, haberleşme, veri aktarımı gibi faaliyetlerde öncelikle askeri alanlarda, devam eden dönemde ise sivil çalışmalarda uydu sistemlerinin kullanılması hem görüş ötesi (LOS) haberleşme zorunluluğunu ortadan kaldırarak “uydu haberleşmesi” tabirini hayatımıza katmış hem de küçük bir alandan ziyade kıta seviyesi alanlarda kapsama alanına sahip olma imkanı sağlamıştır [1].

GNSS sinyalleri yeryüzünde konuşlu sistemlerin konumlarını uzaydaki en az dört uydudan gelen sinyaller doğrultusunda tespit edilmesini amaçlar. Konum, zaman, koordinat, hız gibi bilgilerin tamamı uydu sinyallerinin erişim özelliklerine bakılarak hesaplanmaya çalışılır. GNSS sistemlerinin kendine has doğruluk oranları vardır. Bu oranlar uzayda konuşlu uydu sayısına, uyduların bulunduğu yörüngelere ve uyduların uzaydaki hareketlerine bağlı olarak değişkenlik gösterir. Askeri alanda kullanılması amaçlanan şifrelenmiş GNSS sinyalleri aynı uydudan çıkmasına karşın daha hassas yer sistemleri tarafından hesaplandığı için daha yüksek hassasiyette bir doğrulukla veri üretirken sivil çalışmalara açık olan sinyallerin görece daha yüksek sapma paylarına sahip oldukları bilinmektedir [2].

Sistemlerin GNSS sinyallerine adaptasyonu ve teknolojinin otonom kabiliyetlere erişmesinin arzulanması zamanla bu sinyallere yönelik müdahalelerin sistemlere önemli zarar verebileceği fikrini doğurmuştur. Özellikle ileri teknolojiye sahip alt sistemler ile donatılan askeri platformların zamanla GNSS sistemlerine bağımlı hale gelmesi bu alanda elektronik harp uygulamalarının sıklıkla çalışılmasına ve zamanla ciddi gelişim göstermesine neden olmuştur. “Elektronik karşı önlemler (ECM)” olarak adlandırılan bu karıştırma faaliyetleri “elektronik karşı önlemlere karşı önlemler (ECCM)” olarak adlandırılan ve sinyalin korunmasını, bağlantının sürekli tutulabilmesini, tespit ihtimali düşük sistemlerin geliştirilmesini öncelikleyen sistemlerle aşılmaya çalışılmıştır.

GNSS karıştırması yaklaşımı GNSS sinyallerinin üzerine benzer frekanslarda veya fazlarda

sinyallerin, daha yüksek güçlerle bindirilmesiyle GNSS sinyallerinin bastırılması yaklaşımına dayanır. GNSS sinyalleri orta yörünge uydulardan gelen sinyaller olması nedeniyle gücü zayıf sinyallerdir. Bu nedenle müdahaleye açık sinyaller olarak değerlendirilir. Birçok GNSS sisteminin benzer taşıyıcı frekans bantlarına sahip olması bu müdahalenin kapsayıcı etki yaratmasına neden olmaktadır. Karıştırmaya uğrayan bir sistem konum ve hız bilgilerini doğru tespit edemeyerek çeşitli problemler yaşar [3].

- Hava unsurları bulunduğu irtifayı doğru hesaplayamadığı için çakılması riski doğabilir.
- GÜdümlü sistemlerde ulaşması gereken hedefe ciddi sapmalarla ulaşarak amacın gerçekleşmemesine neden olabilir.
- Kontrolün kaybolmasına ek olarak platformun takibinin tamamen kaybolmasına neden olabilir.
- Askeri haberleşmede GNSS sistemleri, hassas senkronizasyon amacıyla kullanıldığı için korumalı haberleşme engellenebilir.

GNSS Karıştırma faaliyetleri günümüzde savaş sahalarının kaçınılmaz bir gerçeği olarak kabul edilmekte ve bu koşullarda görev icra edebilecek platformların geliştirilmesi öncelikli bir ihtiyaç olarak görülmektedir. GNSS alıcıların çoklanması, INS gibi alternatif navigasyon sistemlerinin de GPS gibi sistemlerle birlikte destek unsurları olarak kullanılması, CRPA gibi karıştırmanın etkisinin azaltılmasını amaçlayan antenlerin kullanılması gibi yaklaşımlar karıştırma ortamında GNSS kullanımı sürekli kılmayı amaçlayan yaklaşımlardan birkaçı olarak ifade edilebilir.

Günümüzde veri sayısının hızla artması verinin anlamlı kısımlarının korunmasını ancak karar sürecinde tesiri olmayacak kısımlarından ise arındırılmasını zorunlu kılmaktadır. Aksi durumda, donanım kısıtları ve zaman kısıtları bu verinin işletilmesini imkansız kılmaktadır. Anlamlandırılan bilginin sürekli, gerçek zamanlı ve genelleşmiş bir karar mekanizmasıyla çalışmasını sağlamak amacıyla makine öğrenmesi yöntemlerinden sıklıkla faydalanılmaktadır. Makine öğrenimi bir algoritmanın kodlanmasına ihtiyaç duyulmadan, sistemin belirli parametreleri dikkate alarak öğrenmesini ve öğrenme sürecinin sürekli şekilde ilerleyerek performansının gelişmesini temel alan bir bilgisayar disiplini. Karar alma mekanizmalarında hızlı çıktı almayı sağlayacak algoritmaların oluşturulmasını temel alır. İnsan bilincinin hatalarından arındırılmış ve uzun sürelerce görev yapabilen sistemler olarak kullanıldığı

alanlarda önemli avantajlar sağlamaktadır.

Makine öğrenmesi yaklaşımından askeri platformlarda ve faaliyetlerde de sınıflandırma, genelleştirme, tespit ve teşhis, kestirim gibi alanlarda sıklıkla faydalanılmaktadır. Hareketlerin tespitine bağlı alışkanlıkların çıkarılması, hedefin bir sonraki zamanda bulunacağı konuma ve harekete dair tahminlerin yürütülmesi, hedefe dair verilerin sınıflandırılarak önceliklendirilmesi gibi birçok kritik alanda makine öğrenmesi çalışmaları ciddi değer yaratmaktadır. GNSS sinyallerine uygulanan karıştırma müdahalelerinin tespit edilmesinde ve indirgenmesinde de makine öğrenmesi avantajlarından faydalanılması arzusu sıklıkla ifade edilmiş ve denenmiştir [4].

Özellikle sınıflandırma problemlerinde makine öğrenmesi yöntemleri etkin çözümler sunmaktadır. Eldeki verinin belirgin özelliklerine göre sınıflandırılabilmesi, veriye göre özelleşmiş aksiyonların geliştirilebilmesi için önem arz etmektedir. Sınıflandırma için birçok farklı yaklaşım bulunmaktadır. Gerçek hayatta veri genellikle birbirinden doğrusal ayrılabilir halde değildir. Bu problemi aşmak için bir sınıfı en yakın komşularına göre sınıflamak bir tercih iken, veriyi de bir üst boyuta çıkararak ayrıştırılabilir hale getirmeyi arzulayan sınıflandırıcı sistemler ayrı bir tercihtir. Sınıflandırma sürecinde en yüksek performansı sağlayan yaklaşım genellikle problemin yapısıyla ilişkilidir. Birçok sınıflandırma yöntemi denenerek en uygun sonucu sağlayan yöntem belirlenebilir [4].

GNSS karıştırma gibi problemlerde de karıştırmanın varlığı ya da karıştırma sinyalini türünün tespit edilmesi süreçlerinde makine öğrenmesi algoritmalarından faydalanılarak sınıflandırma işlemi yapılabilir. Bir müdahalenin varlığının ve müdahalenin türünün bilinmesi sonraki aksiyonların planlanmasına önemli girdiler sağlayabilmektedir.

1.1. Makine Öğrenmesi Yöntemleriyle Karıştırma Tespiti ve Sınıflandırılması

GNSS karıştırma probleminin birçok kez önemli bir problem olarak değerlendirilmiştir. Bu problemin çözümü amacıyla üretilmiş birçok akademik çalışma bulunmaktadır. Bu çalışmalar farklı karıştırma türlerinin çalışması, farklı makine öğrenmesi yönteminin kullanılması, farklı parametrelerle çalışılması gibi yönlerden birbirinden ayrılmıştır.

Bir çalışmada [5] AM karıştırıcı, chirp karıştırıcı ve pulse karıştırıcı olarak üç ayrı karıştırıcı tipi ve karıştırıcının olmadığı durum çok katmanlı algılayıcılar (MLP), uzun kısa süreli bellek

(LSTM) ve rezervuar hesaplama (RC) olacak şekilde üç ayrı makine öğrenmesi yöntemiyle tespit edilmeye ve sınıflandırılmaya çalışılmıştır. GPS sinyalinin L1 bandı 1575.42 Mhz taşıyıcı frekansı ana çalışma değeri olarak belirlenmiştir. Çalışmada iki ayrı yaklaşım benimsenmiş olup bunların ilkinde eğitim setinde karıştırma uygulanmamış GPS sinyallerinden oluşan verilerin verilmiştir. Test aşamasında ise karıştırılmış ve karıştırılmamış GPS sinyallerden oluşan girdiler içerisinde karıştırılmamış GPS sinyallerinin tespit edilmesi amaçlanmıştır. İkinci yaklaşımda ise eğitim setinde üç ayrı tipte karıştırılmış GPS sinyallerinden oluşan veriler girdi olarak sağlanmıştır. Test aşamasında ise yine karıştırılmış ve karıştırılmamış GPS sinyallerinden oluşan girdiler sağlanarak sınıf dışı olarak nitelendirilecek verilerin karıştırılmamış GPS sinyallerini ifade etmesi amaçlanmıştır. Sonuç olarak rezervuar hesaplama (RC) makine öğrenmesi yönteminin her üç karıştırma tipinde de 60 dB karıştırma/sinyal oranına (JSR) kadar olan karıştırma seviyelerinde %1 hata oranıyla en iyi performans sağladığı görülmüştür. Çok katmanlı algılayıcılarla (MLP) makine öğrenmesi yönteminin AM ve darbe karıştırıcı türleri için 20 dB karıştırma/sinyal oranına (JSR) kadar, chirp karıştırma türü için ise 45 dB karıştırma/sinyal oranına (JSR) kadar başarılı sonuçlar verdiği görülmüştür. Son olarak uzun kısa süreli bellek makine öğrenmesi yönteminin ise chirp karıştırıcıları ayırmada çok başarılı olduğu ancak AM ve darbe karıştırıcılarda karıştırma/sinyal oranının (JSR) 40 dB seviyelerine gelmesi durumunda hata oranlarının %10 seviyelerine ulaştığı anlaşılmaktadır.

Bir başka çalışmada [6] AM, FM, darbe, chirp ve NB karıştırma tiplerinin destek vektör makinesi (SVM) ve evrişimli sinir ağları (CNN) makine öğrenmesi yöntemleriyle sınıflandırılması çalışılmıştır. Çalışmada yine GPS L1 bandı baz alınmıştır. Amaç sisteme girdi olarak sağlanan GPS sinyallerinde karıştırmanın varlığını ve sınıfını tespit etmektir. Her bir spektrogram görseli siyah-beyaz 512x512 piksellik bir görsel olarak ifade edilmiştir. Oluşturulan spektrogram görüntülerinin benzer özellikleri bir küme olarak toplanmıştır. Öznitelikler görüntüler üzerinden çıkarılmıştır. Karıştırıcı başına ise yaklaşık 10.000 veri ile oluşturulan öğrenme algoritmalarında gürültü seviyesinin (CN0) 25-50 dBHz bandında olacağı ve karıştırıcı-sinyal oranının (JSR) 40-80 dB bandında olacağı ifade edilmiştir. SVM yönteminin %94.90, CNN yönteminin %91.36 ortalama performans doğruluğu oranıyla iyi bir performans gösterdiği gözlenmiştir. SVM yönteminin en düşük performansı %90.92 oranla AM karıştırıcıyı ayırmakta yaşadığı görülürken CNN yönteminin en düşük performansı %78.41 oranla NB karıştırıcıyı ayırmakta yaşadığı görülmüştür.

Bir başka çalışmada [7] yine AM, FM, pulse, chirp ve NB karıştırma tiplerinin destek vektör makinesi (SVM), lojistik regresyon (LR) ve rastgele orman (RF) makine öğrenmesi yöntemleriyle sınıflandırılması hedeflenmiştir. Yeterince büyük veri elde etmenin zorluğu ve simülasyon ile elde edilen verilerin sayısının limitli kaldığı değerlendirilmesiyle transfer öğrenimi yöntemiyle ImageNet veri setinde önceden eğitilmiş bir evrişimli sinir ağı (CNN) modeli kullanılmış ve öznelikler çıkarılmıştır. Birçok farklı çalışmanın spektrograma odaklı olması nedeniyle performansının kısıtlandığı ifade edilen bu çalışmada spektral yoğunluğu (PSD), spektrogram, histogram ve ham takımyıldızı gibi çeşitli parametrelerin öğrenme sürecinde birlikte kullanıldığı görülmüştür. Çalışma neticesinde destek vektör makinesi (SVM) ve lojistik regresyon (LR) makine öğrenmesi yöntemleriyle yürütülen sınıflandırma işlemlerinde %98 seviyelerinde ve rastgele orman (RF) yöntemiyle yürütülen işlemlerde %96.3 doğruluk oranları sağlanmıştır. Alınan sonuçların geçmişte yapılan çalışmalarda alınan sonuçlarla kıyaslandığında en iyi sonuçlar olduğuna dikkat çekilmiştir.

1.2. Tezin Amacı

GPS sinyalinin L1 bandı 1575.42 Mhz taşıyıcı frekansı bu tezin ana çalışma alanı olarak belirlenmiştir. Çalışma kapsamında AM, FM, chirp ve NB karıştırıcılar ve karıştırıcı olmayan durum olmak üzere 5 ayrı durum set edilmiştir. Belirtilen beş durumun sınıflandırılması amacıyla evrişimli sinir ağları (CNN), destek vektör makineleri (SVM), çok katmanlı algılayıcılar (MLP), sinir ağları (NN) ve rastgele orman (RF) makine öğrenmesi yöntemleriyle çeşitli testler yürütülmüştür.

Gerçekleştirilen literatür araştırması sonucunda GNSS sinyalinin özellikleri incelenerek karıştırma sinyalleri analiz edilecek, karıştırma olmayan ve farklı karıştırma tiplerinin uygulandığı sinyallerinin iki farklı yöntemle öznelik çıkarım işlemleri gerçekleştirilerek farklı makine öğrenme yöntemleri ile sınıflandırılma işlemleri gerçekleştirilecektir. Buna ek olarak öznelik çıkarmaksızın saf veriyle öğrenme işlemlerinin performansı da analiz edilecektir. Hem doğruluk hem de performans açısından sinyal işleme yöntemleri ve makine öğrenme yöntemleri arasından en optimum sınıflandırılmayı veren kombinasyon belirlenecektir.

Yürütülen diğer çalışmalardan farklı olarak tercih edilen makine öğrenmesi yöntemleri farklılaştırılmıştır. Bununla birlikte hazır öğrenilmiş sistemler kullanılmamıştır. Veri sayısı toplanması uzun bir zaman almayacak kadar yüksek adetlerde ya da öğrenmeyi olumsuz et-

kıyıda kadar düşük sayılarda değil performansı en optimum etkileyecek şekilde birçok deneme sonucunda belirlenmiştir. Veri setinin boyutu, öğrenme hızı, momentum katsayısı, eğitim tur sayısı, sinir ağı sayısı, verilerin eğitim ve test için ayrıştırılması gibi parametreler çok kez optimize edilerek en yüksek verim hedeflenmiştir. Karıştırma sinyallerinin gücü belirlenirken sistemi zorlayacak seviyelerde değerler test edilmeye gayret edilmiştir.

Çalışma neticesinde şimdiye dek ortaya koyulanlardan farklı makine öğrenmesi yöntemlerinin karıştırma sınıflandırmaya dair performans kıyasları değerlendirilecektir. Bununla birlikte spektrum analizi yapılırken tercih edilen STFT ve Wigner-Ville dönüşümlerin performansları dayalı farklılıklarına ilişkin detay analizler yürütülecektir. Spektrum analizlerinde en iyi öznelik çıkarımı için iyileştirme çalışmaları ve çıktıları ifade edilecektir. Çalışma 5 farklı durum için 4 farklı makine öğrenmesi yönteminin 2 farklı spektrum analize bağlı performans sonuçlarını ortaya koymayı amaçlanmaktadır.

Bu tez ile GNSS sinyalleri ve makine öğrenmesi kullanılarak karıştırma tiplerinin sınıflandırılabilirliği yeni bir yaklaşımın geliştirilmesi temel amaçtır. Çalışmanın katkılarının şu şekilde olması beklenmektedir;


Gürültü ve karıştırma eklenmiş GNSS sinyallerinin saf verilerinin öznelik çıkarmaksızın doğrudan öğrenme algoritmalarında kullanılmasını önermek, kısa zamanlı Fourier dönüşümü ve Wigner-Ville dağılımıyla elde edilen özneliklerin öğrenme algoritmalarında kullanılmasını önermek, evrişimli sinir ağları (CNN), destek vektör makineleri (SVM), sinir ağları (NN), çok katmanlı algılayıcılar (MLP) ve rastgele orman (RF) tabanlı makine öğrenmesi metodlarıyla %90 üzerinde başarı sağlayan sınıflandırıcı modeller önermek, çeşitli taşıyıcı-gürültü oranı(C/N0), karıştırıcı-sinyal oranı (SJR) ve hiperparametre (Veri setinin boyutu, öğrenme hızı, momentum katsayısı, eğitim tur sayısı, sinir ağı sayısı) koşullarında sonuçları sunmak.

2. GNSS SİSTEMLERİ

2.1. GNSS Kavramı

GNSS sistemleri “küresel konum belirleme sistemleri” ya da “küresel uydu navigasyon sistemleri” olarak ifade edilebilmektedir. Amaç uzayda konumlanmış uydulardan yeryüzüne gönderilen sinyallerin kullanılmasıyla yeryüzündeki alıcıların kendi koordinatlarının hassas ve gerçek zamanlı olarak tespit edilmesini sağlamaktır. Elde edilen bu koordinat bilgisi enlem, boylam ve yükseklik verileriyle ifade edilir. Bu tespit uzaydaki uyduların yerdeki elektronik alıcılara olan anlık uzaklıklarına dayanarak oluşturulur.

GNSS sistemine hizmet eden her bir uydunun yer merkezine olan uzaklık vektörü ρ_s olarak ifade edilirken, yeryüzünde bulunan bir elektronik alıcının yer merkezine göre uzaklık vektörü ρ_r olarak ifade edilirse, her bir uydunun yeryüzündeki bu alıcıya olan uzaklığı ρ olarak ifade edilebilir.



Şekil 2.1.1: Uydu Tabanlı Konumlama Sistemi Prensipli [2]

ρ yeryüzü uzaklığı uydudan gönderilen sinyallerin yeryüzüne ulaşana dek alması gereken yolu ifade etmesi açısından hesaplamalarda kritik önem taşıyan bir veri olarak değerlendirilmektedir. Her ρ yeryüzü uzaklığı, merkezinde ilgili uydunun yer aldığı bir kürenin yüzeyini tanımlar. Bu yöntem kullanılarak üç ayrı uydunun yer merkezi uzaklığı kullanılarak üç uzaklık denklemi çıkarılabilir. Bu denklemler kullanılarak üç bilinmeyen (enlem, boylam

ve yükseklik) tespit edilebilmektedir. Böylece üç uydunun küre yüzeylerinin kesişim noktasında yer alan elektronik alıcının kesin konumu tespit edilebilmektedir [2]. Zaman bilgisinin de tespit edilmesi arzulanması durumunda dördüncü bir uydudan da sinyal alınması gerekir. GNSS sistemlerinde hassas konumlama amacıyla konum ve zaman her zaman birlikte belirlenmektedir.

GNSS sistemi olarak görev yapan çok sayıda uydu takımı bulunmaktadır. Ancak bunlardan en çok kullanımda olanları ifade edilmek istenirse birkaç sistemden bahsedilebilir. GPS sistemi ABD tarafından, GLONASS sistemi Rusya tarafından, GALILEO sistemi Avrupa Birliği ülkeleri tarafından, BEIDOU/COMPASS sistemi Çin tarafından, IRNSS sistemi Hindistan tarafından, QZSS sistemi Japonya tarafından geliştirilen küresel konumlama sistemlerindedir. Bu sistemlere ek olarak Transit, Doris ve Prare gibi navigasyon sistemleri de bulunmaktadır. Ancak bu sistemler ya çok daha eski sistemler olarak ya da mevcut gelişmiş sistemlerin alt versiyonları olarak değerlendirilmektedir. GNSS sistemi en başta çok daha dar bir spektrumu kapsamaktayken GPS, GALILEO, GLONASS gibi sistemler devreye girdikçe bu spektrum genişliği artmıştır. Orta ve üst yörüngelerde GNSS uydu sayısının 100 rakamlarını aşması hem kapsama alanının hem de hassasiyetin artmasına hizmet etmiştir. Avrupa Birliği ülkeleri tarafından desteklenen GALILEO sistemi başlarda belirli ekonomik ve teknik zorluklarla karşılaşmasına karşın günümüzde GNSS sisteminin önemli örneklerinden biri olmuştur. GLONASS sistemi başlarda çok daha küçük bir sistem olarak planlanmasına ve hayata geçirilmesine rağmen 2011 sonrası Rusya'nın petrol gelirlerinin artması neticesinde kaynak yaratılmış ve bugünkü kapsamlı sistem haline evrilmiştir [8].

GNSS alıcıları askeri alandan sivil alana kaydıkça birçok unsurda kendine yer bulmuş ve bu süreç bu sistemlerin zamanla çok daha düşük maliyetlerle üretilmesini gerekli kılmıştır. Başlarda bir GPS alıcısında konum tespitinin daha doğru yapılmasını amaçlayan düşük gürültü amplifikatörü (LNA) çok daha pahalı ve ayrıcalıklı bir bileşen iken bugün bu bileşenin fiyatı 800 kat düşmüş ve dolayısıyla hemen her GPS alıcısında kullanılabilir hale gelmiştir. Bu örnek birçok alt sistemin maliyetlerinde yıllar içerisindeki değişime işaret etmektedir. GNSS alıcılarına dair fiyatların zamanla düşmesinin yanında günümüzde birçok GNSS alıcısı yalnızca bir sistemden değil birçok farklı sistemden konum sinyali olarak en zor koşullarda bile doğru çıktılar vermeyi amaçlayan sinyal bantlarına sahip antenlerle donatılmaktadır [8].


2.1.1. GPS Sistemi

Global Positioning System (Küresel Konumlama Sistemi) olarak ifade edilen, ABD tarafından özellikle ve öncelikle askeri programlarda kullanılmak üzere geliştirilen bir sistemdir. Bu çalışma temelde 1950 yıllarının sonlarında yine ABD ordusu tarafından altı uydunun yaklaşık 1100 km irtifada alçak dünya yörüngesine (LEO) yerleştirdiği ve 150 ve 400 MHz olarak iki taşıyıcı frekans ile yayın yapabilen erken dönem uydu tabanlı konum belirleme sisteminin geliştirilmesiyle elde edilmiştir bir sistemdir. Erken dönem sistemi tek taşıyıcı frekansla çalıştığında 100 m doğrulukta, iki taşıyıcı frekansla birlikte çalıştığında 20 m doğrulukla konum tespiti yapabilmekteydi [9].

GPS sistemi ise 21 asil ve 3 yedek olmak üzere 24 uydunun görev yapacağı şekilde tasarlanan ve uydulardan ilkinin 1978 yılında fırlatılmasıyla başlatılan bir projedir. 1994 senesinde tam olarak işlerlik kazanan proje doğrudan ABD Savunma Bakanlığı tarafından planlanmış ve yürütülmüştür. Uyduların tamamı Blok I, Blok II ve Blok III olacak şekilde yaklaşık olarak 20200 km (MEO) irtifada yörüngeye yerleştirilmiştir. Her ne kadar 24 uydu olarak planlansa da artan ihtiyaçlar ve gelişen teknoloji ile daha önce fırlatılan uyduların geliştirilmesi için GPS Blok III uydularının fırlatılması kararı alınmış ve 2000 yılı sonrasında bu uyduların güncellenmesi çalışmaları başlatılmıştır. Mevcut durumda yörüngede aktif 31 uydu bulunmaktadır. Uydular uzayda 6 yörüngeye konuşlandırılmıştır. Önceki sistemde iki olan taşıyıcı frekans sayısı L1, L2, L3, L4 ve L5 olacak şekilde artırılmıştır. Sistem 5m hassasiyetle konum tespiti yapabilir hale getirilmiştir. L3 frekansının nükleer patlama tespiti için, L4 frekansının iyonosfer kaynaklı düzeltme çalışmaları için, L5 frekansının bir sivil güvenlik sinyali olarak tasarlandığı açıklanmıştır [9].

Teorik olarak yine üç uydudan yeryüzündeki bir alıcının sinyal almasını ve zaman verisi için dördüncü bir uydudan sinyal alınmasını gerekli kılan bir sistemdir. Daha önce açıklanan yöntemle elde edilen doğruluk, yakın zamana kadar yatay bileşen için 100m, dikey bileşen için 156m ve zaman bileşeni için 340 ns ile sınırlıydı ve tümü %95 olasılık düzeyindeydi. Bu düşük doğruluk oranını artırmak için bazı değişiklikler yapılmıştır. Yapılan değişiklikler neticesinde yatay doğruluk oranınının 22m seviyelerine kadar düşürüldüğü ifade edilmektedir. [9].

GPS uyduları çeşitli şekillerde sınıflandırılabilir. En popüler tanımlamada uzay aracının numarasına ve sözde rastgele gürültü oranına bağlı olarak sınıflandırılır. Her GPS uydusu



Şekil 2.1.2: GPS Sistemini Temel Yaklaşımı [10]

L bandı bir sinyalinin içerisinde yer alan iki taşıyıcı, iki kod ve bir navigasyon mesajı taşımaktadır [10]. GPS sistemi daha fazla doppler döngüsüyle ve daha hassas konum tespiti yaklaşımıyla ilk sistemin sahip olduğu eksikliklerin giderilmesi yaklaşımına dayanmaktadır. Ek olarak GPS sistemi konumun ne olduğuna cevap verebilmekle birlikte zamanın ve hızın ne olduğuna dair verileri de yüksek hassasiyetle, anlık ve ucuz şekilde üretebilmektedir [2].

2.1.1.1 GPS Sinyalinin Yapısı

Daha önce de bahsedildiği üzere her bir GPS uydusu bir mikrodalga radyo sinyali üretmektedir. Her sinyal her biri dijital kodlarla modüle edilmiş iki taşıyıcı frekanstan ve bir navigasyon mesajından oluşur. İki taşıyıcı frekanstan biri 1,575.42 MHz (L1) diğeri ise 1,227.60 Mhz (L2) olarak oluşturulmaktadır. Taşıyıcı frekansların dalga boyları ise yaklaşık olarak 19 cm ve 24,4 cm olarak ifade edilmektedir. Bu dalga boyu esasında ışığın boşluktaki hızı ve taşıyıcı frekans arasındaki ilişkiden ortaya çıkarılmaktadır. 2 taşıyıcı frekansın varlığı, iyonosferik gecikme olarak adlandırılan bir GPS hatasını düzeltmeye izin verir. Bütün GPS uyduları aynı L1 ve L2 taşıyıcı frekansına sahiptir. Ancak tüm uydular birbirinden farklı kod modülasyonu kullanır. Bunun amacı sinyal parazitini minimize etmektir. Birbirinden farklı olan bu ikili GPS kodları “kaba yakalama kodu” (C/A-code) ve “hassas kod” (P-code) olarak adlandırılır. C/A-kodu yalnızca L1 taşıyıcı frekansı üzerinde modüle edilirken P-kodu hem L1 hem de L2 taşıyıcı frekansı üzerinde modüle edilmektedir [11].

GPS kodları temelde ikili bir seriden oluşmaktadır. İçerisinde barındırdığı 1 ve 0 rakamlar nedeniyle bu kodlar genellikle PRN olarak bilinir çünkü yapısı rastgele gürültü sinyallere benzer. Ancak bu kodlar temelde bir matematiksel algoritma tarafından üretilirler ve gerçekte rastgele kodlar değildir [11].



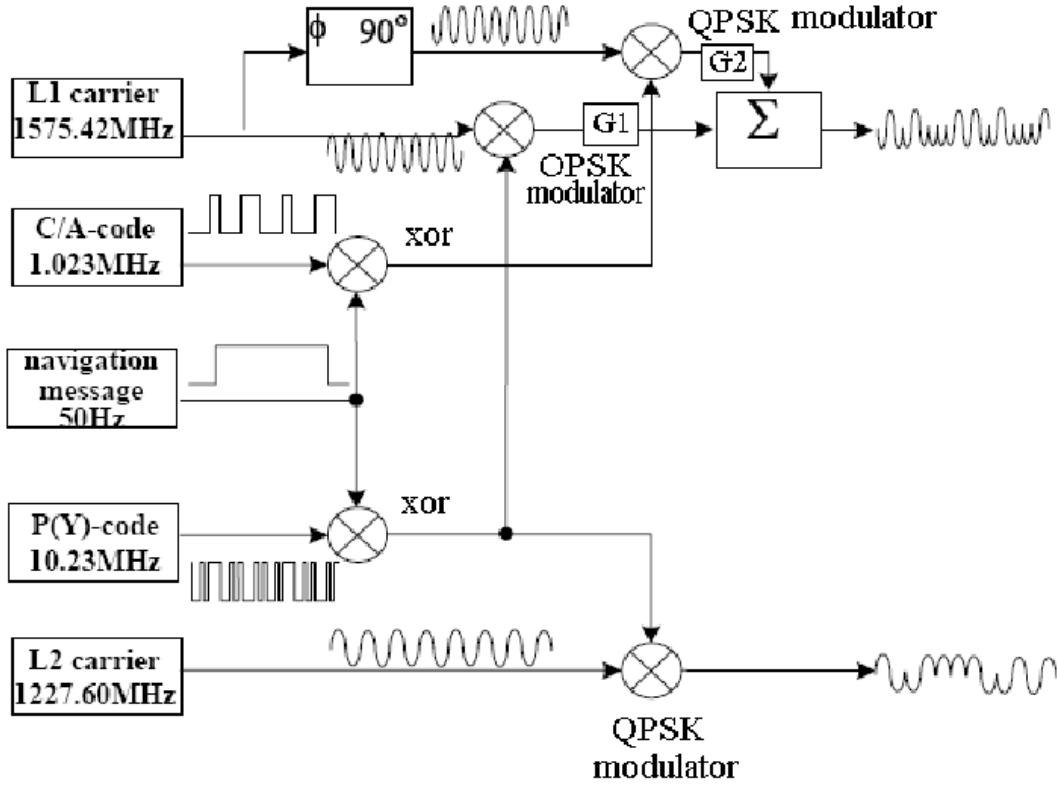
Şekil 2.1.3: (a) Sinusoidal Taşıyıcı Frekans, (b) Dijital Kod [10]

GPS navigasyon mesajı hem L1 hem de L2 taşıyıcılarına 50 kbps gibi düşük hızda iki fazlı bir modülasyonda akışı gerçekleşen bir veridir. Bu mesaj her biri 1500 bitten oluşan veya toplamda 37.500 bitten oluşan 25 çerçeveden oluşmaktadır. Bu, navigasyon mesajının gönderiminin tamamlanmasının her bir çerçeve için 750 saniye sürdüğü anlamına gelmektedir. Bu süre tüm çerçeveler için 12.5 dakikada tamamlanmaktadır [13]. Navigasyon mesajı tüm bu verilerle birlikte ilgili GPS uydusunun konumuna, uydunun sağlık durumuna, uydu saatinin düzeltilmesine dair verilere ve atmosferik verilere dair bilgilere de sahiptir. Her uydu kendi navigasyon mesajını diğer uyduların üzerindeki verileri de kullanarak kendisi iletmektedir. Koordinat bilgisi bu şekilde sağlanabilmektedir.

2.1.2. GLONASS Sistemi

GLONASS sistemi Rusya tarafından başlangıçta askeri navigasyon ve zamanlama sistemi olması amacıyla geliştirilmiştir. Sistem GPS ile benzer şekilde üç ayrı uydudan Dünya üzerindeki bir noktanın pozisyon ve hız vektörlerinin belirlenmesini ve zaman tespiti yapabilmelerini sağlamaktadır. 1995 yılına gelindiğinde Rusya bu sistemin sivil kullanımlara da sunulmasının faydalı olabileceğini değerlendirmiş ve gerekli girişimler başlatılmıştır. Sivil alanda daha çok navigasyon ve jeodezik uygulamalarda kullanılmaktadır [14].

İlk uydusu 1982 yılında fırlatılan GLONASS sisteminde fırlatmalar 1993 yılına kadar devam etmiş ve neticesinde uygulamaya alınmıştır. 1996 yılında 24 uydu sayısına ulaşan sistem tam kapasite çalışma kabiliyetine kavuşmuştur. Her fırlatma faaliyetinde üç uydu üç ayrı yörengeye taşınmıştır. 24 uydudan 15 tanesinin sağlıklı şekilde faaliyetlerine devam edebildiği ifade edilmektedir. Bu nedenle yeni fırlatma faaliyetlerine ihtiyaç olduğu belirtilmektedir. 2011 yılında takımyıldızı operasyonu yeniden başlatılmış ve bu iyileştirme çalışmaları planlanmıştır [14]. GLONASS sisteminin üç ana bileşeni bulunmaktadır; Uzay Bileşeni, Kontrol



Şekil 2.1.4: C/A Kod - P Kod – Navigasyon Mesajı ve Taşıyıcı Sinyallerin Modülasyonu [12]

Bileşeni ve Kullanıcı Bileşeni.

2.1.2.1 Uzay Segmenti

24 uydunun görev yaptığı tam kapasite duruma uzay bileşeni denilmektedir. Her düzlemde 8 uydu eşit şekilde dağıtılmıştır. Uyduların nominal eğimleri 64,8 derecedir ve 120 derecelik boylamlarla birbirlerinden ayrılmışlardır. Uyduların izlediği dairesel yörüngenin yarıçapı yaklaşık 25.510 kilometredir. Uyduların bu yörünge dönüşünü tamamlaması 11 saat 16 dakika sürer. GLONASS sistemi bu yörünge perioduna bağlı olarak Dünya yüzeyinin %99'unda aynı anda en az 5 uydunun sürekli olarak görülebileceğini garanti eden bir çözüm sunmaktadır [14]. GPS ve GLONASS sistemleri için bir karşılaştırma verisi Çizelge 2.1.1 ile verilmiştir.

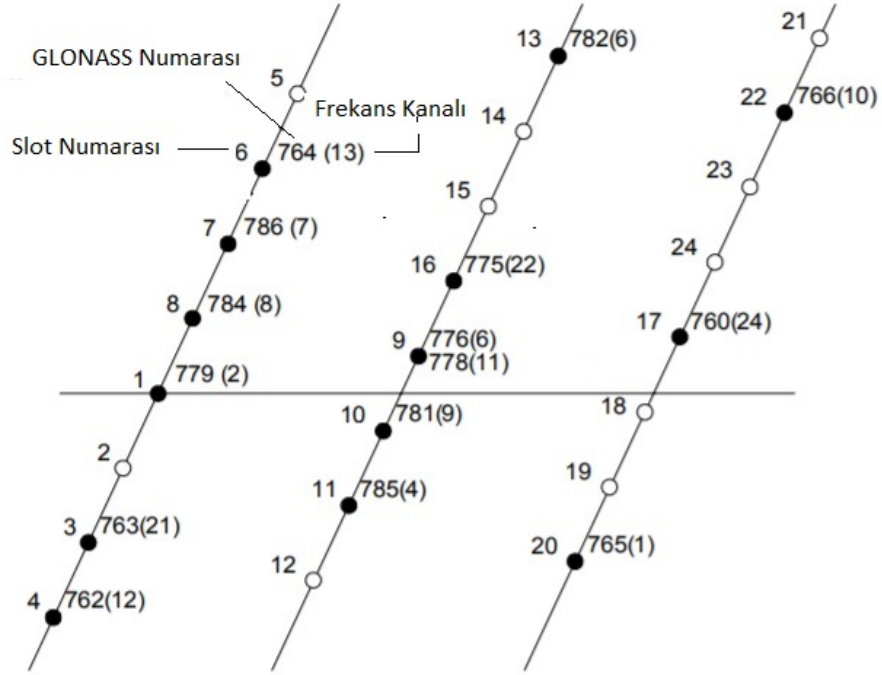
Çizelge 2.1.1: GLONASS Uydularının Yörünge Karakteristiklerinin GPS Uydularıyla Karşılaştırılma Çizelgesi

Özellikler	GLONASS	GPS
Toplam Uydu Sayısı	24	24
Yörünge Düzlemi	3, 120 ° Aralıklarla	6, 60 ° Aralıklarla
Yörünge Düzlemi Eğimi	64.8°	55°
Uydu başına Yörünge Düzlemi	8 eşit parça	6 eşit olmayan parça
Yörünge Yüksekliği	19.100 km	20.200 km
Bir Tur Dönüş Süresi	11 saat 16 dakika	11 saat 58 dakika
Yer İzi Tekrarlanabilirliği	Her 8 yıldız günü	Her yıldız günü
Taşıyıcı Frekans	L1: 1602... 1615.5 MHz L2: 1246... 1256.5 MHz	L1: 1575.42 MHz L2: 1227.60 MHz
Kod	C/A kod L1 P-kod L1 ve L2 tüm uydular için aynı kod	C/A kod L1 P-kod L1 ve L2 Her uydu için farklı kod
Kiplenim	FDMA	CDMA
Kod Frekans	C/A kod: 0.511 MHz P kod: 5.11 MHz	C/A kod: 1.023 MHz PA kod: 10.23 MHz
UTC'ye Göre Sistem zamanı düzenlemesi	UTC(SU)	UTC(USNO)
Uydu Saat Düzeltmesi	saat ofseti frekans ofseti	saat ofseti frekans ofseti frekans oranı
Yörünge Parametreleri	Her 30 dakika uydu pozisyonu uydu hızı uydu ivmesi	Her 60 dakika Düzenlenmiş Keplerian Elementleri

GLONASS uydularından ilk fırlatılanların ömür süresi 3 yıl olarak ifade edilmekteydi. Ancak daha sonra fırlatılan GLONASS-M olarak ifade edilen daha gelişmiş uyduların 5 yıl ömür süresine sahip olacak şekilde tasarlandığı açıklanmıştır. Nihai durumda uydular 3 düzleme yerleşmiş şekilde kendilerine özel bazı değerlerle takip edilirler. Slot numaraları bu oldukları düzlemde her uydunun sahip olduğu numaralardır ve GPS gibi diğer uydulardan ayırt edilmeyi mümkün kılar. Frekans kanalı uyduların nominal frekanslarını ifade eden numaralardır [14].

2.1.2.2 Kontrol Segmenti

GLONASS sisteminin idaresi Yer Tabanlı Kontrol Komitesi adı verilen kontrol merkezlerinden yürütülmektedir. Moskova'da bulunan Sistem Kontrol Merkezi ve farklı lokasyonlarda bulunan Komuta İzleme İstasyonları bu kontrol sistemini oluşturmaktadır. İzleme istasyon-



Şekil 2.1.5: GLONASS Uydularının 17 Mart 1999 Tarihindeki Nihai Yerleşim Gösterimi [14]

ları tüm uyduları izleyerek anlık durumları ve uydu mesajlarını Sistem Kontrol Merkezi'ne aktarır. Mesafe bilgisi 2-3 metre hata payı ile ölçülebilmektedir. Bu bilgi her uydunun saat düzenlemeleri, navigasyon mesajları ve durum bilgileri ölçülürken sabit olarak kullanılır [15].

2.1.2.3 Kullanıcı Segmenti

Kullanıcı segmenti GLONASS alıcılarını ifade etmektedir. Sınırsız sayıda aygıt bu alıcıları içerdiğinden bu segment büyük bir kümeyi içermektedir. GLONASS alıcılarının çalışma mantığı GPS sinyallerinin çalışma mantığına benzer. Bu nedenle içeriği de aynen GPS sisteminde olduğu gibi L1 tek frekanslı alıcılar, L1/L2 çift frekanslı alıcılar, C/A-Kodu ve P-Kodu olarak ifade edilmektedir. Yani aynen GPS sinyallerinde olduğu gibi L1 ve L2 olmak üzere iki taşıyıcı frekans, bir navigasyon mesajı ve C/A ve P kodu olmak üzere de iki GNSS kodu bulunmaktadır. Ancak GPS alıcılarının aksine GLONASS alıcılarının antenleri farklı frekansları da ölçmek üzere artırılmış bir bant genişliğiyle çalışmaktadır [15].

GLONASS sinyallerinde de GPS sinyallerine benzer şekilde L1 sinyali yaklaşık olarak 1.6 GHz , L2 ise 1.2 GHz sinyal frekansına sahiptir. L1 bant taşıyıcı sinyali her ikili (binary)

kodu da kapsarken L2 taşıyıcı sinyali yalnızca P-kodu taşımaktadır. C/A- kodu daha çok sivil uygulamalarda kullanılan ve 0.511 MHz frekansa sahip bir sinyaldir. Buna karşın 5,11 Mhz güce sahip P-kodu genellikle askeri uygulamalarda kullanılan ve daha yüksek hassasiyetli navigasyon kodu olarak adlandırılan bir sinyaldir [15].

2.1.3. GALILEO Sistemi

Avrupa Birliği tarafından geliştirilen GNSS sistemidir. Uydu takımı, yer segmenti ve operasyonun yönetilmesi gibi hususların tamamı için kendine ait çözümleri bulunmakta ve dolayısıyla diğer sistemlerden bağımsız çalışabilmektedir. Ancak diğer küresel konumlandırma uydu sistemlerinin tamamıyla uyumlu çalışabilecek şekilde tasarlanmıştır. Galileo sisteminin ilk nesline dair uydularda pasif saat teknolojisi kullanılmış olmasına karşın daha sonra fırlatılan ve hala devam eden uydu fırlatma çalışmalarında modern sinyal ve saat sistemleri kullanılmıştır [16].

Proje, 30 adet uydunun Dünya yörüngesine yerleştirilmesi planlamasıyla 2005 yılında başlatılmıştır. GALILEO sistemi projesinin başlatılmasındaki en büyük motivasyonlardan biri, GPS gibi sistemlerin askeri kararlardan çok etkilenen ve dinamik süreçlere sahip sistemler olması olarak ifade edilmiştir. Avrupa Birliği'nin ya da Avrupa Uzay Ajansı'nın GALILEO sisteminde yer alan herhangi bir uydunun kapatılmasına ya da yerinin değiştirilmesine dair kararını veremeyeceği, sistemin sivil kullanıma tam olarak açık olacağı vurgusu yapılmıştır [16].

Çizelge 2.1.2: GALILEO Sisteminin GPS Uydularıyla Karşılaştırılma Çizelgesi

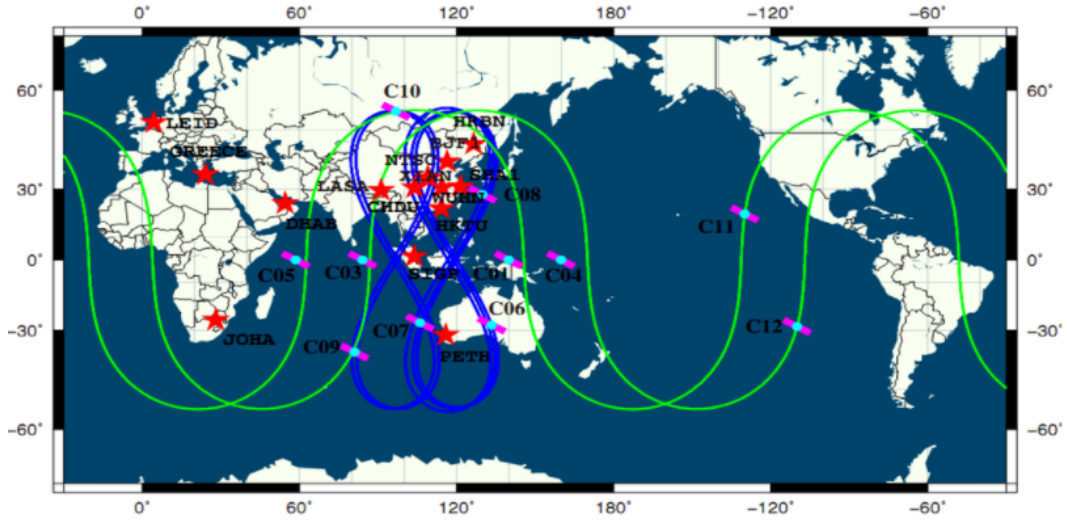
Özellikler	Galileo	GPS
Uyduların Sayısı	27+3	24+3
Yörünge Süresi	14 saat 22 dakika	11 saat 58 dakika
Yükseklik	23616 km	20200 km
En yüksek coğrafi genişlik	60°	55°
Yörünge Sayısı	3	6
Uydulara ilişkin yörüngeler	10	4
Eğim açısı	120°	55°
Yörüngeler arası uzaklık	120°	60°
Frekans	3 frekans	L1: 1575.42 Hertz L2:1227.60 MHz L2:1176.45 MHz
Kiplenim	CDMA	CDMA
Jeodezi koordinat sistemi	GTRF	WGS84
Eş zamanlı referans hızı	Uluslararası TAI	GPS Zamanı = Uluslararası TAI - 19 sn

GALILEO sistemi E1, E2, E5 ve E6 olarak ifade edilen frekanslarda çalışmaktadır. E1 ve E5 frekanslarındaki sinyaller, GPS sisteminde bulunan L1 ve L5 sinyalleri benzerleriyle taşır. Bu nedenle her iki sistem de eşdeğer modülasyon ilkelerini kullanmaktadır. Bunu sağlayabilmek için 2004 yılında her iki sistem de BOC (ikili ofset taşıyıcı) modülasyonuna geçmişlerdir [17]. Bu yaklaşımın temel amacının birden fazla radyo konumlandırma sisteminin bir arada kullanılmasından türetilen bir konum bilgisinin, konumlandırma doğruluğunun artırabileceği düşüncesi olduğu ifade edilmektedir.

2.1.4. BEIDOU Sistemi

Çin tarafından 2000 yılında başlatılan çalışmalarla 2003 yılına kadarki sürede 4 uydu (3 çalışma uydusu 1 yedek uydu olacak şekilde) Dünya yörüngesine oturtulmuştur. Bu çalışmalar Asya - Pasifik bölgesinde ilk navigasyon ve hassas işaretleme çalışmaları olarak nitelendirilir. Bu çalışmalar daha sonra 35 uydunun fırlatılmasıyla devam edecek çalışmaların başlangıcını oluşturmaktaydı. 35 uydunun fırlatılmasıyla gerçek anlamda oluşturulan ve yeni olarak adlandırılabilir sistem ise COMPASS ya da BEIDOU 2 olarak adlandırılmaktadır. Bu çalışmayla birlikte 2011 yılından itibaren Çin bu alanda sivil hizmetler de sağlamaya

başlamıştır [18]. İlk başta fırlatılan BEIDOU 1 sistemi GPS, GLONASS ya da GALILEO sistemlerinden farklı olarak orta yörüngeye konumlandırılmış uydulardır. Bu nedenle uyduların Dünya yüzeyini kapsamı alanları sınırlıdır. Bu eksiklikleri gidermek, sivil kullanımı artırmak, ihtiyaca cevap verebilmek amacıyla Çin COMPASS/BEIDOU 2 olarak adlandırılan sistemi tasarlamıştır. Fırlatılan yeni uydularla Bölgesel Navigasyon Sistemi olarak Çin ve yakın ülkeleri kapsayabilecek bir takımyıldız uydu sistemi kurulabilmiştir. Bu dönemde fırlatılan 35 uydu GEO, MEO ve IGSO yörüngelerine konumlandırılmıştır. Uydulara ek olarak yer kontrol istasyonları, güncelleme istasyonları ve global network dağılım izleme istasyonları kurularak sistemin yardımcı ve yönetici unsurları da tamamlanmıştır [18].



Şekil 2.1.6: Bölgesel BEIDOU 2 ya da COMPASS Olarak İfade Edilen Gelişmiş Sistemdeki Uyduların Yörünge Hareketleri [18]

BEIDOU sistemi çoklu navigasyon sinyalleri iletebilmektedir. Yani iki çeşit servis ağı sağlayabilmektedir. Bunlardan biri açık servis diğeri yetkili servistir. Açık servis olarak ifade edilen ve sivil kullanıcılara hizmet veren serviste konum tespit doğruluğunun 10 metreden, zaman tespit doğruluğunun 20 ns'dan daha iyi ve hız tespit doğruluğunu 0.2 m/s hızdan daha iyi olduğu belirtilmektedir. Yetkili servis olarak adlandırılan hizmetlerde ise konum kestirim doğruluğunun 1m hassasiyetten daha iyi hassasiyete sahiptir. Bu servis için üretilen sinyallerin şifrelenmiş sinyallerdir [19].

Çizelge 2.1.3: BEIDOU Taşıyıcı Frekanslar Çizelgesi

Bant	Frekans	Bileşen	Çip Oranı	Kod Uzunluğu	Gereken Minimum Güç
B1(E2)	1,561.098	I	2.046	2,046	-163 dBW
		Q	2.046		
B3(E6)	1,268.520	I	10.23	10,230	
		Q	10.23		
B1(E5b)	1,207.140	I	2.046	2,046	
		Q	10.23		

COMPASS sistemi B1, B2 ve B3 olarak 3 taşıyıcı frekansta iletilmektedir. Bu frekansların her biri I ve Q olarak ifade edilen bileşenler içermektedir. I bileşeninde kısa kodlar bulunmaktadır ve daha basit bir yapıyla tasarlanmıştır. Bu daha çok sivil kullanımlar için önemlidir. Q bileşeni ise daha uzun kodlardan oluşmakla birlikte genellikle şifrelenmiş yetkili kullanımlar için önemlidir. COMPASS sisteminin taşıyıcı frekansları GALILEO sisteminin E1-E2-E5 ve E6 bantlarına tam olarak denk gelmektedir. Bu durum iki sistemin alıcılarında üst üste binme sorunları yaşanmasına neden olmaktadır [20]. BEIDOU sistemi 2021 yılı içinde tam takım olarak devreye alınmıştır.

3. GNSS KARIŞTIRMA VE ANALİZ YÖNTEMLERİ

3.1. GNSS Karıştırıcı Sistemler

GNSS sinyallerinin gücü çok uzak mesafelerde konuşlu uydulardan üretilen sinyaller olması nedeniyle düşüktür. Bu zayıflık GNSS sinyallerinin karıştırılmasını kolaylaştırmaktadır. Çoğu zaman uydu sinyallerinin gürültü ile maskelenerek karıştırılması, SNR değerinin düşürülerek karıştırılması ya da aynı frekansta yüksek güçte bir sinyalin alıcıya iletilmesiyle karıştırılması gibi yöntemler uygulanabilmektedir [3].

Karıştırma bilinçli şekilde bir sinyalin bozulması amacıyla yapıldığı gibi kimi zaman da kasıtsız şekilde sinyallerin bozulmasına neden olan bazı nedenlerle de yaşanabilmektedir. Hava durumları, sinyal üreten cihazlardaki hatalar zaman zaman istenmeyen GNSS girişimlerine neden olabilmektedir.

Kasıtlı karıştırma kontrol edilen bir sinyalin ayırt edilemez olmasını amaçlar. Sinyalle aynı modülasyonda, aynı frekansta yeterli güce sahip bir verici, alıcıdaki bir sinyali kolaylıkla karıştırabilir. Temel amaç alıcının sinyalden doğru bilginin almasını engellemek ve kullanıcı için girişim oluşturmaktır [3].

Dijital sinyallerde modülasyon daha karmaşık bir yapıda olduğundan karıştırma sinyalleri bu modülasyona tam uygun olamayabilir. Alıcı ve verici arasındaki bağılılığa adapte olamayan karıştırma sinyali, alıcıyı sinyal aldığına inandırabilir ancak iletimin son bulduğuna dair gerekli veriyi içeren sinyali iletemez. Bu durumda karıştırma sinyali alıcıyı sinyal alış verişinin bitmediğine ve sürekli devam ettiğine inandırarak bir döngüye sokabilir [3].

Çok sayıda karıştırma türü bulunmaktadır. Bunlardan birkaçı AM karıştırıcı, FM karıştırıcı, NB karıştırıcı, Chirp karıştırıcı olarak ifade edilebilir [6].

3.1.1. AM Karıştırıcı

En çok çalışılan karıştırıcı tipi olarak ifade edilmektedir. AM (Amplitude Modulation) karıştırıcı sinyalleri verilen denklemde “k” değerine bağlı olarak çok tonlu ya da tek tonlu olarak tasarlanabilmektedir. “k” değeri 1’den büyük seçilirse çok tonlu karıştırıcı sinyali üretilmiş olur. AM karıştırıcı sinyali aynı zamanda “sürekli dalga karıştırıcı sinyalleri” olarak da bilinmektedir. “k” değeri karıştırıcı bileşenlerinin sayısını ifade eder. Karıştırıcı bileşen gücü

(P_{J_k}) , taşıyıcı frekansı (f_{J_k}) ve fazı (θ_{J_k}), üç ayrı parametre ile Eşitlik 3.1.1'deki gibi ifade edilir [6].

$$j(t) = \sum_{k=1}^K \sqrt{P_{J_k}} \exp(j(2\pi f_{J_k} t + \theta_{J_k})) \quad (3.1.1)$$

3.1.2. FM Karıştırıcı

FM karıştırıcılar (Frequency Modulation), AM karıştırıcılarda olduğu gibi tek tonlu ya da çok tonlu olabilir. “ k ” değeri yine ton sayısını ifade eder ve eğer 1’den büyükse çok tonlu karıştırıcı sinyali üretilmiş olur. “ k ” adet karıştırıcı bileşenin modülasyon değerine β_k parametresi Eşitlik 3.1.2'deki gibi dahil edilir [6].

$$j(t) = \sum_{k=1}^K \sqrt{P_{J_k}} \exp(j(2\pi f_{J_k} t + \beta_k \sin(2\pi f_k t))) \quad (3.1.2)$$

3.1.3. NB Karıştırıcı

Narrow Bant (Dar Bant) karıştırıcı sinyalleridir. Çok daha yüksek bir güçle dar bir bantta karıştırma gerçekleştirilmesi amaçlandığında tercih edilen karıştırıcı çeşitlerindedir. $n(\zeta)$ değeri ise “0” ortalamalı ve A varyanslı bir durağan rastgele süreci Eşitlik 3.1.3'deki gibi ifade eder [6].

$$j(t) = \sqrt{P_{J_k}} \cos \left(2\pi f_{J_k} t + \beta \int_0^t n(\zeta) d\zeta + \theta_{J_k} \right) \quad (3.1.3)$$

3.1.4. Chirp Karıştırıcı

Chirp (Cıvıltı) karıştırıcılar frekansın zaman üzerinde doğrusal olarak modüle edildiği karıştırma sinyalleridir. Belirli bir frekans aralığında belirli bir zaman boyunca frekanslar doğrusal olarak süpürülür. Belirlenen frekans aralığının sonuna gelindiğinde süpürme işlemi ilk frekansta ancak farklı bir zaman boyunca yeniden başlatılır. Bu durum testere dişine benzer bir süpürme alanı ortaya çıkarır. Bu nedenle bu sinyallere testere dişi chirp bozucular da denilir. (P_J), karıştırma sinyalinin gücünü ifade ederken, (f_{J_k}) süpürme frekans aralığının başlama noktasını ifade eder. (f_{min}) ve (f_{max}) süpürme yapılacak frekans aralığını, (T_{swp}) ise süpürme yapılacak zaman aralığını Eşitlik 3.1.4'deki gibi ifade eder [6].

$$\begin{aligned}
j(t) &= \sqrt{P_J} \exp(j(2\pi f_J t + \pi b \frac{(f_{max} - f_{min})}{T_{swp}} t^2 + \theta_J)) \\
&= \sqrt{P_J} \exp(j(f_q(t)t + \theta_J))
\end{aligned} \tag{3.1.4}$$

3.2. Gürültü


Gürültü ifadesi temelde esas sinyalin içerisinde yer alan, bilinmeyen ve çözüme sorun oluşturan tüm bozulmalar için kullanılmaktadır. Sinyal, alıcılar vasıtasıyla elde edilirken kasıtlı ya da kasıtsız gürültüler sinyale karıştığı gibi bir sinyal üzerinde işlem yapılırken ya da sinyal farklı formlara dönüştürülürken de gürültü karışabilmektedir.

Bir GNSS sinyaline kasten uygulanan karıştırma ve aldatma sinyaline ek olarak gürültü gibi negatif unsurların da eklenmesi, esas veriye ulaşmakta önemli zorluklar oluşturmaktadır. Esas sinyale ulaşmak için arzulanan hızla ve sinyal bilgisinden feragat etmeden, her özellikte gürültünün elenebileceği tasarımların geliştirilmesi önemli bir problemdir [21].

Birçok örnekte bu problemi aşmak amacıyla özelleşmiş filtreler geliştirilerek ya da anten tasarımları optimize edilerek SNR değerini artırılmaya ve esas sinyale en doğru şekilde ulaşılmaya çalışılmaktadır. Burada önemli olan sinyal gücünün gürültü gücüne olan oranının yüksek olmasıdır. Bu veriler dB birimleriyle ifade edilir [21].

Çok sayıda gürültü çeşidi bulunmaktadır. Eklemeli gürültü, birçok rastgele sürecin etkisine benzetilerek oluşturulan temel bir gürültü yapısıdır. Beyaz eklemeli gürültü, gauss dağılıma sahip eklemeli gürültü gibi çeşitleri bulunmaktadır. Beyaz eklemeli gürültü farklı frekanslarda eşit güç yoğunluğuna sahip eklemeli bir gürültüdür. Gauss dağılıma sahip gürültü ise belirli bir varyans ve ortalama değeriyle bir “normali” ifade eder [22].

Bunların haricinde, güçlü bir darbe sonrası etkisi gittikçe azalan gürültüler geçici gürültülere örnek olarak verilebilir. Yüksek bir güçle kısa aralıklarla ve kısa sürelerle gerçekleşen gürültülere ise patlamalı gürültü denilebilir [22].



Şekil 3.2.1: Esas Sinyal, Gürültü ve Gürültü Eklenmiş Bozulmuş Sinyal Gösterimi [23]

3.3. Sinyal İşleme Teknikleri

3.3.1. Kısa Zamanlı Fourier Dönüşümü (STFT)

Fourier dönüşümü temelde zaman tabanlı bir sinyalin frekans tabanlı bir versiyona dönüştürmeyi amaçlar. Bu dönüşümün temel gayesi sinyal üzerinde daha kolay işlem yapılabilecek ve daha kolay yorumlanabilecek bir boyut elde edebilmektir.

1987 yılında Fransız matematikçi Jean-Baptiste Joseph Fourier'in sinüs ve kosinüs fonksiyonlarının toplamının bir fonksiyon olarak ifade edilmesine yönelik yürüttüğü çalışmalar neticesinde bu dönüşüm keşfedilmiştir. Devam eden çalışmalarda Fourier sinyali oluşturan sinüs ve kosinüs sinyallerinin ayrı ayrı genliklerinin bulunmasının da yine mümkün olduğu aynı bilim adamı tarafından ortaya konmuştur. Bu çalışmalar neticesinde ortaya çıkan yönteme Fourier Dönüşüm adı verilmiştir [24].

Fourier Dönüşüm ile bir zaman sinyalinin farklı frekans, genlik ve büyüklüğe sahip sinüsoidal sinyallerin toplamından oluşabileceği ve daha sonra bu farklı sinyallere geri erişmenin mümkün olabileceği ifade edilir. Bu durum karmaşık zaman sinyallerinin frekans tabana çevrilerek farklı frekans ve genliklere sahip ayrı parçalar olarak incelenebilmesine imkan sağlamıştır. Fourier dönüşüm zaman tabanlı sinyaller sürekli bir sinyal olduğunda farklı, ayrık

sinyaller olduğunda farklı bir formülasyon ile gerçekleştirilmektedir [25].

$$\begin{aligned} \mathbf{F}(\omega) &= \sum_{n=0}^{N-1} \mathbf{f}(n) e^{-j2\pi(n\frac{\omega}{N})} \\ \mathbf{f}(n) &= \frac{1}{N} \sum_{w=0}^{N-1} \mathbf{F}(w) e^{j2\pi(w\frac{n}{N})} \end{aligned} \quad (3.3.1)$$

Ayrık sinyallerin Fourier ve ters Fourier dönüşüm 3.3.1'deki gibi ve sürekli sinyallerin Fourier ve ters Fourier dönüşümü Eşitlik 3.3.2'deki gibi verilmektedir [25].


$$\begin{aligned} \mathbf{F}(\omega) &= \int_{-\infty}^{\infty} \mathbf{f}(t) e^{-i\omega t} dt \\ \mathbf{f}(t) &= \frac{1}{2\pi} \int_{-\infty}^{\infty} \mathbf{F}(\omega) e^{i\omega t} d\omega \end{aligned} \quad (3.3.2)$$

Ayrık sinyallerde Fourier dönüşüm çözümü sürekli sinyallerde uygulanan çözümden temelde farklı değildir. Ancak N adet örneğe spesifik zamanlarda dönüşüm yapılması amacıyla formülasyonda integral işlemi yerine o noktalarda toplam işlemi yapılarak çözüm elde edilmiştir. Ancak ayrık Fourier dönüşüm problemlerinde N dizi uzunluğunun büyük olması durumunda çok fazla sayıda karmaşık çarpma ve bölme işlemi yapılması gereği doğmaktadır. Bu durum doğrudan ayrık Fourier dönüşümünün kullanılmasını zorlu kılmaktadır. Bu soruna 1965 yılında J. W. Cooley ve John Tukey bir çözüm getirerek işlem miktarını azaltmıştır. Geliştirilen hızlı çözümler Hızlı Fourier Dönüşüm olarak adlandırılmıştır [26].

Hızlı Fourier dönüşümü, temelde ayrık Fourier dönüşüm'den farklı olmayan ancak N dizi sayısının parçalanarak azaltılmasıyla işlem yükünün azaltılması bakış açısına dayanan bir yöntemdir. N dizi sayısı tek ve çift sayı indisli olarak bölünür. Böylece N/2 sayılı bir dizi elde edilerek iki ayrı ayrık Fourier dönüşüm hesaplanır. Eğer gerekli görülürse N/2 sayılı dizi bir de tek ve çift indislerine ayrılacak şekilde N/4 dizi sayılı gruplara bölünebilir. Azaltılmış N dizi sayıları üzerinde ayrık Fourier dönüşüm işlemi yapılarak daha sonra elde edilen veriler birleştirilir. Böylece yüksek N sayılı diziye sahip olan bir sinyalin Fourier dönüşümü tamamlanmış olur [26].

Sürekli sinyaller, genlik değerinin genişliği boyunca tüm zaman aralığında değer alan sinyallerdir. Ayrık sinyaller ise zaman içerisinde belirli noktalarda belirli değerlere sahip olan,

tüm genlik genişliği boyunca her an bir değere sahip olmayan sinyallerdir



$$x(t) = \sin(2\pi f_o t)$$

$$x(n) = \sin(2\pi f_o n t_s)$$

Şekil 3.3.1: Ayrık ve Sürekli Sinyallerin Gösterimi [27]

Kısa zamanlı Fourier dönüşüm ise hızlı Fourier dönüşümü gibi sinyalin tüm genliği boyunca sinyali tek seferde incelemek yerine parça parça incelemeyi hedefleyen bir diğer yöntemdir. Bir sinyalin zaman değiştiğinde, belirlenen pencere içerisine giren kısmının analiz edilerek sinüsoidal frekanslarının ve faz değerlerinin belirlenmesi hedeflenir. Temelde uzun ve akan bir sinyalin üzerinden bir pencere geçirilirken, pencere içerisine giren parçalarının Fourier dönüşümlerini alma işlemidir. Sinyalin eşit parçalarda Fourier spektrumları çıkarılmış olur. Akan bir sinyalin pencereye giren bölümlerine bağlı olarak değişen spektrumlarını zamana bağlı bir fonksiyon olarak üretir. Tercih edilen pencere sinyalin üzerinde kaydırılarak tüm sinyal boyunca bu işlem yürütülür [28].

Sürekli sinyallerde doğrudan Fourier dönüşüm yerine kısa zamanlı Fourier dönüşümün tercih edilmesinin temel sebeplerinden birisi zaman bilgisinin kaybolmasının istenmemesidir. Kullanılan pencere temelde zaman bilgisini korumayı amaçlar. Bu pencere genellikle bir Gauss pencere olabilir. Kısa zamanlı Fourier dönüşümün normal Fourier dönüşümden en önemli farkı budur [28].


Sinyalin pencere içine alınması ve ilgili kısmın Fourier dönüşümü Eşitlik 3.3.3'de ifade edilmiştir [29].

$$s_\omega(t, \tau) = s(\tau)\omega(\tau - t) \tag{3.3.3}$$

$$F_s^\omega(t, f) = F_{\tau \rightarrow f} \{s(\tau)\omega(\tau - t)\}$$

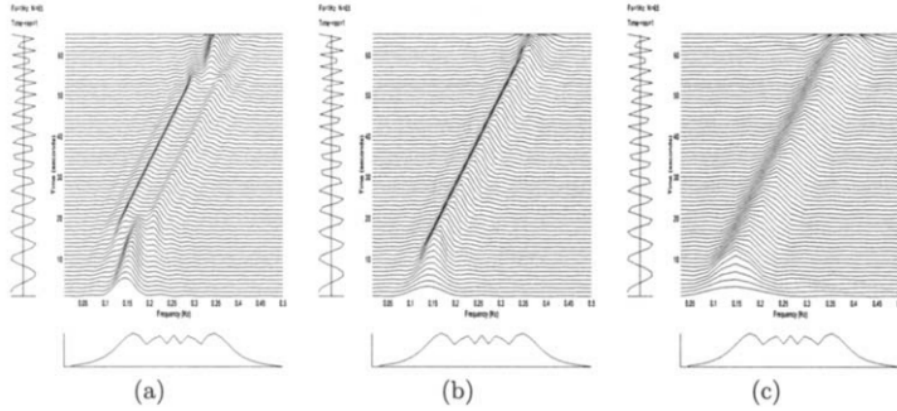
Sinyalin pencerelenmesi ve pencere içinde kalan kısmın kısa zamanlı Fourier dönüşüm uy-

gulanmasın dair formülasyonlar yukarıda verilmiştir.



Şekil 3.3.2: Kısa Zamanlı Fourier Dönüşüm Uygulaması Gösterimi [30]

Kısa zamanlı Fourier dönüşümlerde temel eksiklik ise sinyalin ilgili pencere içerisine giren bölümüne odaklı bir analizin yapıyor olmasıdır. Bu durum sinyalin bir kısmının dönüşümü yapılırken uygulanan integral işleminde yalnızca pencere içerisindeki kısmın frekans genişliğinin alınmasına neden olmaktadır. Pencerenin nasıl belirleneceği zaman-frekans çözünürlüğünde belirleyici rol oynamaktadır. Temelde zaman ekseninde artırılan farkındalığın frekans bilgisinde bir kaybı beraberinde getirdiği görülmektedir [28].



Şekil 3.3.3: Başlangıç Frekansı 0.1 ve Bitiş Frekansı 0.4 Olan Doğrusal Bir FM Sinyali Üzerinde Farklı Boyutlardaki Pencerele Kısır Zamanlı Fourier Dönüşümün Etkileri [29]

Farklı pencere boyutlarıyla kısa zamanlı Fourier dönüşüm uygulanan bir doğrusal FM sinyalinin sonuçları verilmiştir. Pencere boyutları arttıkça frekanstaki kazancın arttığı ancak zamandaki çözünürlüğün azaldığı görülmektedir.

3.3.2. Wigner-Ville Dağılımı

Wigner-Ville dağılım fonksiyonu da Fourier dönüşüm gibi zaman ve frekans tabanlı sinyallerin analizlerinde kullanılmaktadır. 1932 yılında kuantum fiziği üzerinde çalışmalar yapan Eugene Wigner tarafından keşfedilmiştir. Wigner-Ville dağılımı temelde bir sinyalin üzerinde herhangi bir zamanda verilen frekans aralığında istatistiksel olarak enerjinin ya da güç seviyesinin dağılımını ifade eder [31].

$z(t)$ sinyalinin Wigner-Ville dağılım formülasyonu Eşitlik 3.3.4'de ifade edilmiştir [29].

$$W_z(t, f) = \int_{-\infty}^{\infty} z\left(t + \frac{\tau}{2}\right) z^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f\tau} d\tau \quad (3.3.4)$$

Güç spektrumunun hesaplanması için bir otokorelasyon fonksiyonunun kullanılması temeline dayanır. Sinyal mümkün olan tüm göreceli kaymalar ve gecikmeler uygulanarak kendisiyle kıyaslanır. Otokorelasyon fonksiyonu bu sayede üretilir. Wigner dağılımı yapılan çalışmalarda dağılım spektrumunda görünen ancak sinyalde gerçekte var olmayan, dağılımın doğrusal olmaması nedeniyle oluşan bir girişim gözlenmektedir.

Wigner Dağılım formülasyonu Eşitlik 3.3.5'de ifade edilmiştir [29].

$$W_z(t, f) = \int_{-\infty}^{\infty} z\left(t + \frac{\tau}{2}\right) z^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f\tau} d\tau \quad (3.3.5)$$

Eğer $z(t)$ sabit bir fonksiyonsa ve f_c frekanslı bir sinyal ise $\delta(f)$ girişimi oluşmuş Wigner Dağılım formülasyonu Eşitlik 3.3.6'deki gibi verilebilir [29].


$$W_s(t, f) = \frac{1}{4}\delta(f - f_c) + \frac{1}{4}\delta(f + f_c) + \frac{1}{2}\left[\cos(2\pi 2f_c t)\right]\delta(f) \quad (3.3.6)$$

Bu girişimin oluşması Wigner dağılımının sinyal üzerinde doğrudan kullanılması önünde önemli bir engel oluşturmaktadır. Bu durum sinyallerin kendisi yerine benzetimiyle oluşturulan bir sinyalin kullanılması fikrini doğurmuştur. Sinyallerin pozitif ve negatif bileşenlerinin simetrik olduğu ve aynı veriye sahip olduğu bilinmektedir. Bu durum negatif bileşenin çıkarılması durumunda herhangi bir bilgi kaybının olmayacağı şeklinde yorumlanır. Negatif bileşenler-

den kurtulmanın hem hızı artıracığı hem de istenmeyen girişimleri önleyeceği yaklaşımı izlenmiştir. Wigner – Ville dağılımı Wigner dağılımdan farklı olarak bahse konu istenmeyen girişimden kurtulmak için sinyalin kendisi yerine negatif bileşenlerinden arındırılmış halini kullanır [29].

Wigner-Ville dağılımında da, kısa zamanlı Fourier dönüşümde olduğu gibi bir pencere sinyal üzerinde kaydırılarak ilgili kısımların frekans spektrumları çıkarılır. Ancak farklı olarak sinyalin frekans bilgisi elde edilirken sinyalin sadece pencere içindeki kısmının değil tamamının zaman ve frekans bilgisi kullanılarak spektrum üretilir [32].

Wigner-Ville dağılımı, kısa zamanlı Fourier dönüşüm gibi sadece belirli bir pencere içerisindeki frekans sınırlarına dayanarak hesap yapmadığı için sızıntılardan etkilenmez. Bu nedenle matematiksel olarak mümkün olan en doğru zaman - frekans analizi çıkarır. Wigner-Ville dağılımının en önemli dezavantajı ise sinyalin birden fazla frekans bileşenine sahip olması durumunda Wigner-Ville bu bileşenlerin arasına büyük çapraz terimler ekler. Bu büyük çapraz terimler Wigner-Ville dağılımının performansını olumsuz etkilemektedir. Bu durum genişletilmiş (yumuşatılmış) Wigner-Ville dağılımıyla çözülmeye çalışılabilir. Bazı geçirgen filtrelerin kullanılmasıyla bu çapraz terimlerden kurtulmak amaçlanır. Zaman filtresi genellikle $g(t)$, frekans filtresi ise $h(f)$ ile ifade edilir. Bu yaklaşım da kimi zaman performansta beklenen artışı sağlayamayabilir [29].



Şekil 3.3.4: Çapraz Terimlerin Etkisinin Azaltılması İçin Yumuşatılmış Wigner-Ville uygulaması Örneği [33]

Şekilde, kullanılan geçirgen zaman filtresinin ve frekans filtresinin değerine bağlı olarak çapraz terimlerin etkisinin nasıl değiştiği görülmektedir. Yumuşatılmış Wigner-Ville dağılım ve doğru filtreler ile çapraz terimler giderilmiştir. Bununla birlikte çözünürlükte de bir kayıp olduğu görülmektedir.

Kısa zamanlı Fourier dönüşümde çapraz terim sorunu bulunmamaktadır. Bunu ek olarak çalı-

şılması kolay ve işlem hızı yüksek çözümlerdir. Ancak frekans-zaman çözünürlüğü arasında kritik bir dengeye sahiptir. Çözünürlüğün iki unsur için de yüksek tutulması mümkün olamamaktadır. Bununla birlikte Wigner-Ville dönüşümde çözünürlüğün yüksek olmasının önemli bir avantaj olduğu daha önce de ifade edilmiştir. Çapraz terim sorununun aşılması için Yumuşatılmış Wigner-Ville kullanılarak bu sorunun aşılabileceği ancak bu çözümün çözünürlükte bazı kayıplara neden olduğu görülmektedir. Wigner-Ville dönüşümde sinyal üzerinde negatif bileşenlerin atılması gibi işlemler bir işlem yükü doğurmaktadır. Bu durum hesaplama hızında belirli zorluklara neden olmaktadır [29].

3.4. Makine Öğrenmesi Yöntemleri


Makine öğrenmesi yaklaşımı bugün birçok problemin çözümünde tercih edilen yöntemlerden olmuştur. İnsanın karar mekanizmasındaki emeğini sıfırlamayı ya da azaltmayı amaçlayan, daha önce eğitildiği verilere dayanarak yeni durumlara doğru kararlar vermeyi hedefleyen sistemlerdir. Tasarlanan öğrenme modellerinde parametrelerin belirlenmesinde ve verilerin normalize edilmesi süreçlerinde tasarımcı yaklaşımı sistemin performansını doğrudan etkilemektedir.

Birçok makine öğrenmesi yöntemi bulunmakla birlikte, rastgele orman algoritmaları, destek vektör makineleri, çok katmanlı algılayıcılar, sinir ağları ve evrişimli sinir ağları modelleri makine öğrenmesi çalışmalarının birkaç örneği olarak ifade edilebilir.

3.4.1. Rastgele Orman

Rastgele ormanlar denetimli sınıflandırma özelliğine sahip sistemlerdir. Yani veri seti ve bu veri setinden elde edilmesi gereken çıktı özel olarak bellidir. Denetimli öğrenme süreçleri sistem verilerini ve verilerden elde edilen sonuçları tekrar tekrar kullanarak bir regresyon ya da sınıflandırma algoritması oluşturmayı amaçlar [34]. Böylece sonradan eklenecek verilere dair sınıflandırma ve regresyon problemlerinde kullanılmak üzere en uygun değer değerlendirme parametresi elde edilmiş olur.

Rastgele ormanlar, eğitim veri seti içerisinde rastgele seçilen bir kümeyi kullanan birden çok karar ağacının eğitilerek her bir karar ağacının bir oy hakkına sahip olacak şekilde sınıflandırma kararı vermesini amaçlayan sistemlerdir. Birçok karar ağacını içerisinde barındırır. Rastgele ormandaki ağaç sayısı ve bu ağaçlar arasındaki ilişki sistemin hata oranına ve performansına doğrudan etki eder. Karar ağacı sayısı arttıkça değerlendirme döngüsü daha da arttığı için sistemin performansı artar [34].



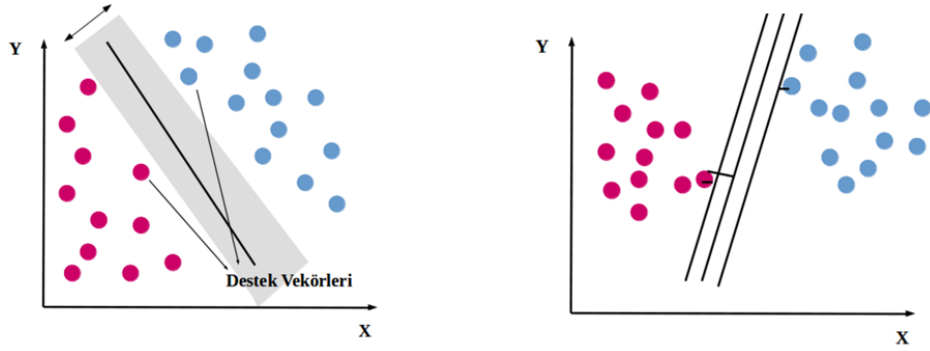
Şekil 3.4.1: Rastgele Orman Şeması [35]

Sistemin önemli avantajlarından birisi eğitim setinde yer alan verilerin bölünerek karar ağaçlarına girdi olarak verilmesidir. Bu sayede öğrenme süresi tek bir karar ağacına kıyasla önemli ölçüde kısalmaktadır. Her karar ağacı sonucu bir oy hakkına sahip olduğu için sistemin bir parçasında meydana gelebilecek hata ya da önyargıların sistemin bütününe etkisi tek bir karar ağacı kullanılan sistemlere kıyasla çok daha düşüktür. Zira nihai sınıflandırma kararı en çok oyun alındığı karar doğrultusunda verilir [34].

3.4.2. Destek Vektör Makineleri

Destek vektörü makineleri, çoğunlukla sınıflandırma çalışmaları için zaman zaman ise regresyon çalışmaları için kullanılabilen bir makine öğrenmesi yöntemidir. Denetimli bir öğrenme algoritmasıdır. Sahip olunan veriler n adet özelliğine göre bir düzlemde belirli koordinatlara yerleştirilir. Daha sonra n özelliği kullanarak yapılan koordinatlandırmaya bağlı olarak bir hiper düzlem bulur ve iki sınıfı birbirinden en doğru şekilde ayırmaya çalışır. Yani destek vektör makinesi, iki sınıfı en iyi ayıran bir çizgiyi ya da düzlemi ifade eden vektörün algoritmasını yansıtır [36].


Destek vektör makineleri iki sınıfı birbirini ayıran en doğru düzlemi belirlemeye çalışırken, her iki sınıfın birbirine en yakın olan örneklerinin en uzağında olan düzlemi seçmeye gayret eder. Ayrıcı düzlemin ya da çizginin her iki sınıfa ait örneklere de en uzak noktada seçilmesi ve kenar boşluklarının uzak tutulmaya gayret edilmesinin temel amacı ise sistemin güvenilirliğini artırmaktır. Bu yaklaşım yeni örneklerin, tasarlanmış sınıflandırma sistemine eklenmesi durumunda hataya en uzak sistem tasarlanmış olması amacına hizmet eder. Zira



Şekil 3.4.2: Destek Vektör Makineleri Çalışma Prensibi [37]

destek vektör makinesi algoritmalarının temel gayelerinden biri de kategorisi bilinmeyen yeni örneklerin doğru sınıfa atanmasını sağlamaktır [36].

Destek vektör makineleri doğrusal olmayan sınıflandırma problemlerinde de en yüksek başarımla sınıflandırma yapabilmektedir. Aykırı verilerin olması durumunda da destek vektör makineleri yüksek performansa sahip sınıflandırmalar yapabilmektedir [38]. Destek vektör makineleri doğrusal olmayan problemleri sınıflandırmak için çekirdekleme adı verilen bir yöntemi kullanır. Bu yöntemde örneklerin konumlandırıldığı koordinatlar bir üst boyutta ifade edilerek daha ayrılabilir bir konumlandırma elde edilmesi amaçlanır. Sınıfları ayrılabilir bir forma taşımak için sınıfların buldukları düzlemde bir üst boyuta geçilir. Örnek olarak, iki boyutta ifade edilen bir doğrusal ayrılamayan veri setinin üç boyuta geçirilmesi durumunda bir düzlem ile ayrılabilir olabileceği yaklaşımından faydalanılır.




Şekil 3.4.3: Destek Vektör Makinelerinde Çekirdekleme Yöntemiyle Boyut Artırma [39]

3.4.3. Çok Katmanlı Algılayıcı


Sinir ağı çalışmalarının ilk örneklerinden biri tek katmanlı algılayıcılardır. Tek katmanlı algılayıcılar bir sinir hücresinin birden çok girdiyi işleterek bir çıktı sağlaması mantığına dayanır. Gelişmiş sinir ağı yapılarında olduğu gibi her girdiyi sinir ağına bağlayan bağlantının

belirli bir ağırlığı vardır. Eğer çıktı, hedeflenen ile aynı ya da benzer değilse ağırlıklar revize edilir ve çıktı yeniden hesaplanır. Toplam işareti sinir ağındaki toplam fonksiyonu, b ifadesi ön yargıyı (ezberlemeyi), fonksiyon ifadesi aktivasyon fonksiyonunu ifade eder. Tek katmanlı algılayıcılar doğrusal ayrılabilir problemlerde yeterli performansı sağlayabilmektedir. Ancak doğrusal ayrılamayan ya da daha karmaşık problemlerin çözümünde tek katmanlı algılayıcıların geliştirilmesi gereği ortaya çıkmıştır [40].



Şekil 3.4.4: Tek Katmanlı Algılayıcılar [40]

Tek katmanlı algılayıcılar AND, OR ya da NOT gibi mantık kapılarına dair ayırma işlemlerini gerçekleştirebilirken XOR gibi doğrusal ayrılamayan işlemlerde öğrenmeyi ya da sınıflandırmayı başarıyla gerçekleştirememesi, temelde çok katmanlı algılayıcıların çalışmasına zemin oluşturmuştur. XOR probleminde veriler doğrusal ayrılabilir olmadığından bu problem gizli katmanlar eklenerek çok katmanlı hale getirilmiş bir algılayıcı yöntemiyle çözülmüştür [40].




Şekil 3.4.5: XOR Doğruluk Tablosu [41]

Rumelhart ve ekibi tarafından çözülen bu problem ile oluşturulan çok katmanlı algılayıcı temelde birbirine bağlı çok sayıda tek katmanlı algılayıcıdan oluşur. İlk katmana giriş katmanı,

son katmana çıkış katmanı ve arada ki katmanlara ise gizli katmanlar adı verilir. Öğrenme işlemi ilk başlatılırken ağırlıklar birbiriyle aynı olmayacak şekilde rastgele küçük değerlerle set edilerek başlatılır [42].

Çok katmanlı algılayıcılarda, belirlenen ağırlıklar çıkış performansına göre otomatik olarak birbiriyle ilişkili olarak güncellenebilir. Sinir ağı üzerindeki eğitim en doğru performans elde edilene dek “geri yayılım” ile ağırlıklar sürekli güncellenir. Çok katmanlı algılayıcıda ayrıca her katmandaki her sinir hücresi bir sonraki her sinir hücresiyle direk bağlıdır. Tek katmanlı algılayıcılara kıyasla en büyük farklardan biri budur [42].



Şekil 3.4.6: Çok Katmanlı Algılayıcı Modeli [40]

3.4.4. Sinir Ağları


Sinir ağları temelde insan beyninin bilgisayarlarla modellenmesi amacını taşımaktadır. Bir sinir ağı giriş katmanından, nöronlardan, bir veya daha fazla gizli nöron katmanından ve son çıkış nöronundan oluşmuştur. Nöronlar arası her bağlantı bir ağırlığa sahiptir. Her nöronun girdisi, nöron içinde belirli olan bir aktivasyon (transfer) fonksiyonuyla ve ilgili ağırlığıyla işlenilerek o nöronun çıktısını oluşturur. Aktivasyon fonksiyonları ayrıca sinir ağı'nın farklı nöronlar tarafından felç edilmemesini de sağlamaktadır. Aktivasyon fonksiyonları değişken olabilir. Yaygın bir örnek olarak sigmoid fonksiyonları Eşitlik 3.4.1'deki gibi verilebilir [43].

$$\sigma(\mu) = \frac{1}{1 + \exp(-\mu)} \quad (3.4.1)$$

Bir nöronun çıktısı hesaplanırken $V_{i,j}$ ilgili nöronun ağırlığını, x_j inputu, N input nöronlarının sayısını, σ aktivasyon fonksiyonunu, T_i ise ilgili gizli sinir ağlarının eşik değerini ifade etmektedir [43]. Bu ifade Eşitlik 3.4.2'deki gibi gösterilebilir.

$$h_i = \sigma\left(\sum_{j=1}^N V_{i,j}x_j + T_i^{hid}\right) \quad (3.4.2)$$

Giriş nöronlarına verilen güncel girdiler çıkış nöronlarında döndürülen ağırlıklara ve fonksiyonlara bağlı olarak belirlenirler. Çıkış nöronlarının çıktısının doğruluğuna ve performansına bağlı olarak tüm bağlantıların ağırlıkları optimize edilerek giriş nöronlarına yeniden girdi sağlanır. Nihai performansın en optimum seviyeye ulaştığı zaman kadar bu ağırlıkların revize edilmesi süreci devam eder [43].



Şekil 3.4.7: Bir Sinir Ağı Gösterimi [44]


3.4.4.1 Evrişimli Sinir Ağları

Evrişimli sinir ağları son yıllarda örüntü tanıma problemlerinde sıkça kullanılan bir makine öğrenmesi yöntemidir. Görüntü işleme, ses tanıma, yüz tanıma gibi problemlerde yüksek performans sergilediği sıklıkla ifade edilmektedir. Evrişimli sinir ağlarını, yapay sinir ağlarından ayıran bazı özellikleri bulunmaktadır. Bunlardan biri parametre sayısının çok daha az olmasıdır. Bu sayede daha karmaşık problemlerin çözümünde evrişimli sinir ağlarının çok daha yüksek performans sergilediği ifade edilir [45].

Evrişimli sinir ağlarının bir diğer özelliklerinden biri de bağımlı özelliklere sahip olmamasıdır. Örnek olarak, evrişimli sinir ağı kullanılarak tasarlanan bir yüz tanıma sisteminde taranan görüntülerde “yüz” görsellerinin yerini tam olarak bilmeye gerek yoktur. Sistemin tek amacı “yüz” tespit etmektir. Eğer yüz görselleri tespit edilebilirse eşleme ya da sınıflandırma

yapılabilir [45].


Evrışimli sinir ağlarını, yapay sinir ağlarından ayıran diğer önemli özelliklerinden biri de derin katmanlara inildikçe daha yüksek seviyeye sahip özelliklerin filtrelenebilir olmasını sağlamasıdır. Örnek vermek gerekirse bir görüntü sınıflandırma sisteminde ilk katmanda kenarları filtrelemesi amaçlanırken diğer katmanda bazı şekillerin filtrelenmesi ve bir sonraki katmanda daha yüksek seviye de örnek gerekirse doğrudan yüz figürlerinin filtrelenmesi amaçlanmaktadır [46].



Şekil 3.4.8: Yüz Tanıma Amacıyla Tasarlanmış Olan Bir Evrişimli Sinir Ağının Katmanlarında Yer Alan Filtreleme Örneği [45]


Giriş katmanını yalnızca bir nöronlu gizli katmana bağlamak için $32 \times 32 \times 3$ adet bağlantı kurulması gereken bir evrişimli sinir ağı olsun. Yapay sinir ağlarıyla burada gizli katmana bir nöron daha eklemek istendiğinde ilave $32 \times 32 \times 3$ bağlantı olması gerekecektir. Böylece ağırlık parametre sayısı $32 \times 32 \times 3 \times 2$ olarak 6000'den fazla ağırlık parametresi kullanılacaktır. Ancak aynı işlem evrişimli sinir ağı ile tasarlanmak istenirse 32×32 olarak yaklaşık 1000 adet ağırlık parametresine ihtiyaç olacaktır. Bu durum parametre sayısının neden daha az olduğunu ortaya koymaktadır. Ek olarak çok karmaşık işlemlerde gizli katmanda iki nöron sayısının yeterli olmayacağı değerlendirildiğinde nöron sayısı artırıldıkça parametre sayısının

daki artışının katlanarak devam edeceği görülmektedir. Bu karmaşıklığa sahip sistemlerde de evrişimli sinir ağlarının sağlayacağı fayda anlaşılmaktadır [46].



Şekil 3.4.9: 32X32X3 Bağlantıya Sahip Bir Evrişimli Sinir Ağı Gösterimi [45]

Evrişimli sinir ağlarında filtreler matrislerle ifade edilir. Bu filtreler kimi zaman görüntünün ortalamasını almayı amaçlarken kimi zaman kenarların daha belirgin olmasını sağlayacak şekilde çeşitlidir.



Şekil 3.4.10: Matris Filtrelerden Örnek Gösterim [47]

3.4.5. Öznitelik Çıkarımı

Öznitelik çıkarımı öğrenme algoritmalarında verinin tamamı yerine bu verinin bu veriden ayırt edici unsurları bularak onlarla çalışmayı sağlar. Özniteliklerin doğru seçilmesi sinir ağının performansını doğrudan etkileyeceğinden en doğru müşterek özniteliklerin belirlenerek sisteme öğrenmesi için verilmesi arzulanır. Öznitelikler belirlenirken bu sayının çok fazla olması sistemin genelleşmiş bir yaklaşım öğrenebilmesinden ziyade veri parçalarına adapte olmuş ve aşırı uyumlanmış bir öğrenim sergilemesine neden olur. Öznitelik sayısı arttıkça sistemde meydana gelen ezberleme ve aşırı uyumun ortadan kaldırılması için veri sayısının ve çeşitliliğinin artırılması ihtiyacı doğar. Bu durum sistemin üzerinde gerekli olmayan sayıda verinin koşturulmasına ve dolayısıyla büyük bellek alanlarına, işlem güçlerine ihtiyaç duyulmasına neden olur. Ayrıca öznitelik sayısı arttıkça sinir ağı modelinin boyutu da sinir ağına yapılan her bir girdinin karşılanması gereği nedeniyle artar. Veri bulutunun çok büyük

olması ve ihtiyaç duyulmayacak çok fazla içeriğin varlığı bugünün en büyük problemlerindedir. Bununla birlikte kapasite sorunu ve işlemci yükü ise olabildiğince kısıtlıdır. Bu nedenlerle öznitelik çıkarımı makine öğrenmesi ve sinir ağları uygulamalarında en belirleyici unsurlardan biri olarak değerlendirilmektedir [48].

Öznitelik sayısının gereğinden az olması ise eldeki verilerin sınıflandırılabilmesi için sisteme yeteri kadar argüman verilememesi anlamına gelecektir. Bu durum verilerin birbirinden farklarını ifade edecek parametrelerin tam olarak ortaya konulmaması anlamına gelmektedir. Bununla birlikte öznitelik sayısının istenmeyecek şekilde az olması bazı özniteliklerin sistemde daha baskın olmasına ve karar mekanizmaları üzerinde baskın olmasına neden olacaktır [48].

Öznitelikler belirlenirken temel yaklaşım belirgin ve önemli özellikleri ortaya çıkarırken değersiz özellikleri değerlendirme dışı tutmaktır. Veriyi yeteri sayıda doğru ifadeyle açıklayabilir olmak hedeflenir. Öznitelik çıkarımı için birçok farklı yaklaşım bulunmaktadır. FFT, DFT, STFT, Wigner-Ville gibi yöntemler öznitelik çıkarmak için kullanılan önemli yöntemlerdir. Buna ek olarak PCA, LDA gibi yöntemlerle boyut indirme yoluyla ya da gürültüden arındırma teknikleriyle öznitelikler çıkarılmaya çalışılabilir [49].

3.4.6. Veriyi ve Öznitelikleri Sınıflandırma Algoritmalarına Hazırlama İşlemleri

Sınıflandırmada temel mantık, sınıfları bilinen bir grup verinin özelliklerini ve niteliklerini kullanılarak ayırıcı unsurların tespit edilmesinin ve bu unsurlar sayesinde yeni verilerin doğru şekilde birbirinden ayrıştırılmasının sağlanmasıdır. Ayırıcı unsurların doğru belirlenmesi, eğitim verilerinden doğru çıktılarının alınmasına doğrudan bağlıdır. Bu nedenle en doğruya yakın değerlendirme metriklerini sağlaması için eğitim verileri üzerinde bazı iyileştirme ve saflaştırma çalışmaları yürütülür. Bu aşamada yalnızca verimizi iyileştirmek için faydalandığımız yöntemlerin literatür araştırmalarına yer verilmiştir.

3.4.6.1 Veriyi ve Öznitelikleri Ayırma Yaklaşımı

Bir problemin derin öğrenme yöntemleriyle aşılması ihtiyacını duyan bir geliştirici, probleme bağlı olarak öncelikle öğrenme mimarisini tasarlar. Tasarlanan mimarinin yapısına uygun olarak etiketlenen verinin bir kısmı sistemin eğitimi için kullanılır. Eldeki verinin bir kısmı sistemin eğitilmesi sürecinde bir kısmı ise test edilmesi sürecinde kullanılır. Test seti içerisindeki verinin bir kısmı sistemin önyargı ya da tahmin hatalarının tespit edilerek test

öncesinde iyileştirilmesi (eğitimin doğrulanması) amacıyla kullanılır. Test setinin asıl amacı ise sistemin belirlediği ayırıcı unsurların probleme dayalı mümkün olabilecek tüm veriler için doğru sonuç verip veremediğinin analizinin yapılmasıdır. Eğitim seti, doğrulama seti ve test seti arasında benzer bir genelleme bulunmamasına özen gösterilir. Aksi takdirde sistem, muhatap olduğu tüm verilerin benzer bir yaklaşımına evrilmiş şekilde karar vermeye odaklanacaktır. Bu durum probleme dayalı her koşulun doğru test edilmemiş olması anlamına gelir ve sistemin performansını negatif etkiler. Bu durum “aşırı eğitilmişlik” olarak ifade edilir. Bu durumun etkisinin azaltılması amacıyla eğitim verilerinin ve test verilerinin birbiriyle çok eşlenir ve benzer veriler olmaması arzulanır. Ancak sistemin tasarımı ve yaklaşımı belirli bir problemi çözmeye odaklandığından bu verilerin birbirinden özellik ve nitelik bakımında tamamen farklı olması da sistemin doğru performans sergilememesine neden olur. Bu nedenle veri seti içinde bu yaklaşımlarla bir dengenin kurulması esas gerekliliklerdendir [4].

Temelde eğitim setiyle öğrenme, eldeki ilk veriler ışığında sistemin öğrenme yaklaşımını ve sinir ağları arasındaki ağırlıkların belirlenmesini sağlarken doğrulama setiyle test etme işlemi sistemin optimizasyonu için gerekli alanların bulunmasını arzular. Doğrulama setiyle yürütülen test sonucuna göre eğitim sürecinde aynı veriyle kaç öğrenme döngü oluşturulmasının en iyi olduğu, kaç nöron kullanılmasının performansı artırdığı ya da sistemin karar hızının hangi koşulda nasıl değiştiği gibi değerlendirmeler yapılabilmektedir. Test setiyle yürütülen test faaliyetinin amacı ise sistemin tamamlanmış konfigürasyonunun nihai performansını eğitim ve doğrulama setindeki verilerden bir miktar ayrılmış görece daha yeni verilerle gözlemlemektir [4].

Eldeki veri tüm bu yaklaşımlar ışığında belirli oranlarda bölünerek sisteme girdi sağlayacak şekilde hazırlanır.

3.4.6.2 Normalizasyon

Normalleştirilmenin amacı verilerin özelliklerini benzer bir ölçekte olacak şekilde dönüştürmektir. Bu sistemin performansını ve eğitim kararlılığını artırır. Sistemin bir özelliği ezberlemesine neden olacak ağırlıklardan kurtulmayı sağlar. Makine öğrenmesi yöntemlerinde her verinin normalleştirilmesi bir zorunluluk değildir. Ancak karmaşık sistemlerde veri çeşitliliği, verinin özellikleri arasında ciddi farklılıklar olmasına ve bu nedenle normalleştirme uygulamalarının kaçınılmaz olmasına neden olmaktadır. Birkaç çeşit normalleştirme metodu bulunur. Minimum - maksimum normalleştirme, Z ölçeği normalleştirme bunlardan birkaçı

olarak ifade edilebilir [50].

Eşitlik 3.4.3’de verilen minimum – maksimum normalleştirmede verilerin özelliklerinin belirtildiği her sütunun en yüksek değerinden en minimum değeri çıkarılır ve elde edilen değer toplam sütun sayısına bölünür. Böylece elde edilecek yeni sütunlardaki tüm değerler 0 ile 1 arasında normalize edilmiş olacaktır. En çok tercih edilen normalleştirme türlerindedir [50].

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.4.3)$$

Z ölçeği normalleştirmede (standartlaştırma) amaç Eşitlik 3.4.4’de verildiği gibi her özelliğin değerini sıfırda ortalayarak varyansı 1 olan standarda kavuşturmadır. Her gözlemin ortalamasını çıkarılır ve ardından standart sapmaya bölünür. En çok tercih edilen normalleştirme türlerindedir [50].

$$z = \frac{x - \mu}{\sigma} \quad (3.4.4)$$

3.4.6.3 Hiperparametre Seçimi

Hiperparametreler sınıflandırma problemlerinde sınıfların birbirinden en doğru şekilde ayrılmasını amaçlayan noktaların tespit edilmesini sağlayan değerlendirmelerdir. Makine öğrenmesi temelde bu parametreleri en doğru şekilde tespit etmeyi amaçlayan bir çalışma prensibine sahiptir. Bir sınıflandırma probleminde birden fazla parametre tercihi yapılabilir. Örnek olarak k- en yakın komşu sınıflandırma algoritması tercih edildiğinde “k” değerinin kaç olacağı tasarımcı tarafından kararı verilmesi gereken bir değerlendirmedir. Veri setinin boyutu, öğrenme hızı, momentum katsayısı, eğitim tur sayısı, sinir ağı sayısı gibi kararların tamamı sistemin performansını doğrudan etkileyecek kararlar olacaktır. Bu değerlendirmede en yüksek performansı sağlayan hiperparametrenin tercih edilmesi önemlidir. Birçok hiperparametre belirleme ya da belirlenen hiperparametreyi iyileştirme yöntemi bulunur. Izgara arama, çapraz doğrulama gibi yöntemler bu yöntemlerden birkaçı olarak ifade edilir [51].

3.4.6.3.1 Izgara Arama Yöntemi

Hiperparametre optimizasyonunu yapılırken verinin büyüklüğü ve özellikleri hangi yönte-

min kullanılacağı konusunda belirleyici unsurlardan biridir. Izgara arama yöntemi en çok tercih edilen optimizasyon yöntemlerinden biridir. Burada bir hiperparametreler ızgarası kurulur ve öğrenme modeli bu ızgaradaki kombinasyonların her biri üzerinde eğitilir ve test edilir. Izgara arama yöntemindeki tüm parametrelerin kombinasyonlarının denenmesi, veri sayısının çok yüksek olduğu durumlarda çok yüksek işlem gücü getirebilir. Farklı hiperparametre optimizasyonu yöntemlerinde de zaman zaman benzer dezavantajlar ortaya çıkmaktadır. Rastgele arama yöntemi, önceden öngörmenin zor olduğu hiperparametre değerlerini bulmayı da amaçladığı genellikle işlem süresi uzun olan bir yöntem olarak ifade edilmektedir. Bu gibi durumlarda ızgara aramada kullanılacak parametre sayısını azaltmak ve en doğru parametreleri seçebilmek için öncesinde rastgele arama yöntemiyle hangi parametrelerin daha iyi çalıştığına bakılarak bu sonuca bağlı olarak ızgara arama parametreleri seçilebilir [51].

3.4.7. Karışıklık Matrisi

Karışıklık matrisi tasarlanan öğrenme algoritmasının performansını ölçmeyi amaçlayan bir matristir. Gerçek değeri bilinen bir test verisi karar algoritmalarına sokularak elde edilen sonuç ile gerçek değer aynı olup olmadığı incelenir. Böylece sistemin iyileştirme ihtiyacı olup olmadığı kararına girdi sağlanır [52].

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 3.4.11: Karışıklık Matrisi Tablosu [53]

- **Gerçek Pozitifler (TP)**

Doğru tahmin edilen pozitif değerlerdir. Gerçek değer ile tahmin edilen değer aynı olduğu durumlardır.

- **Gerçek Negatifler (TN)**

Doğru tahmin edilen negatif değerlerdir. Gerçek değer ile tahmin edilen değer aynı olduğu durumlardır.

- **Yanlış Pozitifler (YP)**

Yanlış tahmin edilen negatif değerlerdir. Gerçek değer ile tahmin edilen değer farklı olduğu durumlardır.

- **Yanlış Negatifler (FN)**

Yanlış tahmin edilen pozitif değerlerdir. Gerçek değer ile tahmin edilen değer farklı olduğu durumlardır.

- **Kesinlik**

Doğru sınıflandırılan verilerin oranıdır [54]. Kesinlik P ile ifade edilirse;

$$P = \frac{TP}{TP + FP} \quad (3.4.5)$$

- **Duyarlılık**

Yalnızca pozitif değerlerden doğru oranlarının oranıdır [54]. Duyarlılık S ile ifade edilirse;

$$S = \frac{TP}{TP + FN} \quad (3.4.6)$$

- **Özgüllük**

Yalnızca negatif değerlerden doğru oranlarının oranıdır [54]. Özgüllük G ile ifade edilirse;

$$G = \frac{TN}{TN + FP} \quad (3.4.7)$$

- **F Skoru**

Kesinlik ve Duyarlılık değerlerinin harmonik ortalamasıdır [54]. F skoru F ile ifade edilirse;

$$F = 2 \frac{PS}{P + S} \quad (3.4.8)$$

- **Doğruluk**

Sistemin çalışma doğruluğunu ifade eder [54]. Doğruluk D ile ifade edilirse,

$$D = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.4.9)$$

4. GNSS KARIŞTIRMA TİPİ SINIFLANDIRMA ÇALIŞMALARI

4.1. Sinyallerin Oluşturulması

$s(t)$ GNSS sinyallerine, $n(t)$ gürültü, $j(t)$ karıştırıcı sinyallerinin eklenerek $r(t)$ sinyallerin oluşturulması hedeflenmektedir. Çalışmada aldatma (spoofing) sinyallerinin bulunmadığı kabul edildiğinden buna dair bir sinyal üretilmemiştir. Üretilen her GNSS sinyali birbirlerinden farklı güçlere, frekanslara ve faz değerlerine sahip gürültü ve karıştırma sinyalleriyle çeşitlendirilmiştir.

$$r(t) = s(t) + n(t) + j(t) \quad (4.1.1)$$

Üretilen GNSS sinyallerine SNR değeri 0 ile -45 dB arasında rastgele olacak şekilde beyaz gürültü ekleme işlemi gerçekleştirilmektedir.

Karıştırma uygulanan senaryolarda GNSS sinyallerine dört farklı karıştırma tipi uygulanmaktadır. Bu türler AM, Chirp, FM, NB olarak ifade edilebilir. Bu dört farklı karıştırıcı tipine sahip sinyaller ve karıştırıcı içermeyen sinyaller ile birlikte toplamda beş farklı tipte GNSS sinyaline sahip bir veri seti oluşturulmaktadır. Senaryo başına 10.000 sinyal olmak üzere 5 durum için toplamda 50.000 sinyal üretilmiştir

GNSS sinyallerinde elde edilen bozulmanın etkisinin gösterilmesi amacıyla karıştırıcı ve gürültü içermeyen GNSS sinyalinin, karıştırıcı içermeyen ancak gürültü içeren GNSS sinyalinin, gürültü içermeyen ancak AM, FM, NB ve Chirp karıştırıcılar içeren GNSS sinyalinin ve hem gürültü hem de AM, FM, NB ve Chirp karıştırıcılar içeren GNSS sinyalinin analizleri yapılmıştır.

Tüm durumlara dair sinyal analiz modelleri oluşturulmuştur. Bu modellerden her bir durum için bir örnek verilmiştir. Bu analizler karıştırıcının ve gürültünün sinyallerdeki değişimi ifade etmektedir. Örnek sinyallerde reel ve kompleks kısımların "genlik - zaman analizleri" verilerek sinyalin yapısı hakkında bilgi alınması hedeflenmiştir. Her periyotta 1057x1 büyüklüğünde matrislerden oluşan veriler elde edilmektedir.

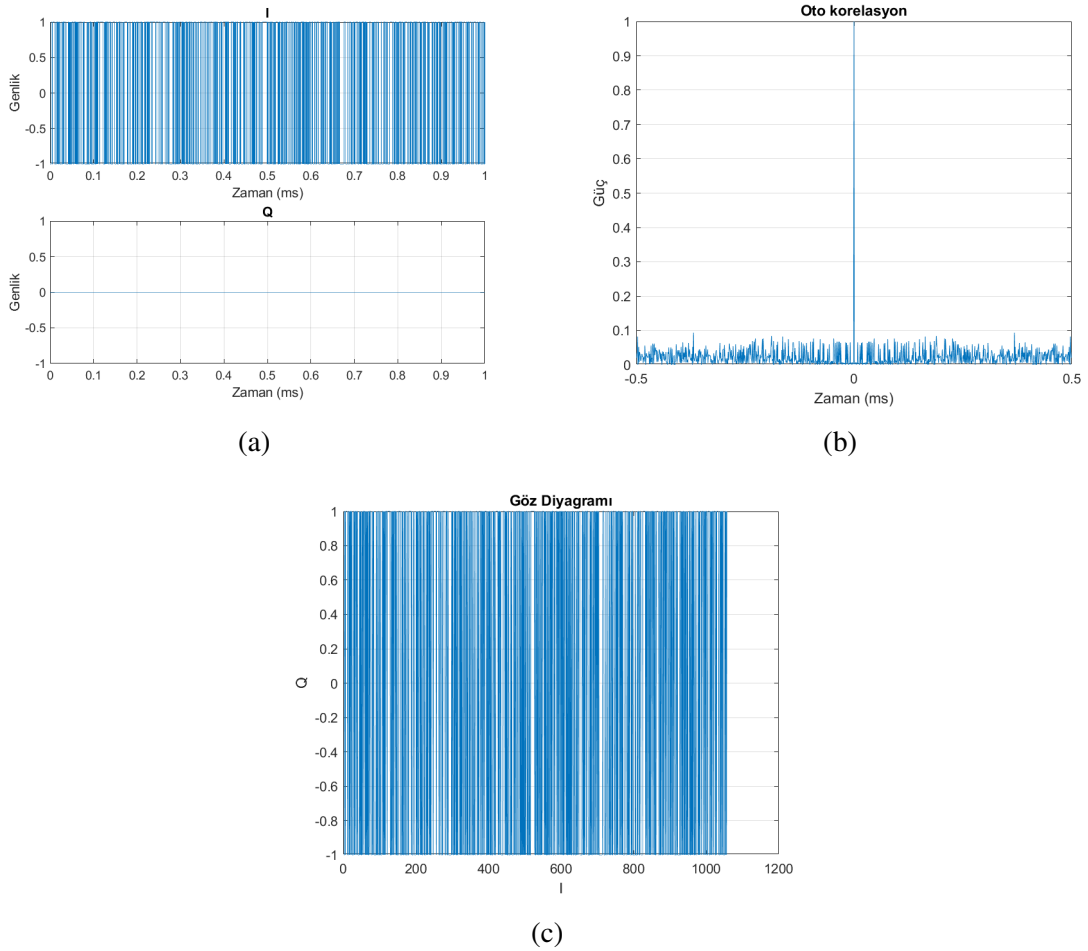
Örnek sinyallerde "otokorelasyon analizleri" verilerek sinyalin tekrar eden örüntülerine ya da görünür olmayan önemli frekanslarının tespit edilmesine dair analizler yürütülmüştür. Böylece sinyalin farklı zamanlardaki çıktılarının birbiriyle korelasyonu incelenmiştir.

Sinyalin genel kalitesini deęerlendirmede önemli parametrelerden biri olan ve zamanlama hassasiyeti, geçici durumlar ve gürültü marjı gibi konularda önemli tespitler sağlayan "göz diyagramı analizleri" de sinyallerde karıştırıcının sinyal üzerinde yarattığı etkiyi göstermek için incelenmiştir.

4.1.1. Karıştırıcı ve Gürültü İçermeyen GNSS Sinyali

$$r(t) = s(t) \quad (4.1.2)$$

Modülasyon tipi GPS L1 C/A olan, örnekleme frekansı 1057 Mhz olan ve periyodu 1 msn olan bir GNSS sinyali üretilmiştir. Gürültü bulunmamaktadır.



Şekil 4.1.1: Karıştırıcı ve Gürültü İçermeyen GNSS Sinyal Analizleri

Üretilen sinyalin gerçek kısmı 1 ve -1 değerleri alan bir genliğe sahipken kompleks kısmı daima 0 değerini almaktadır; $Q = 0$ ve $I \neq 0$

Sinyalin otokorelasyon analizinde güç değerinin yalnızca $t = 0$ anında 1 değerini alacak bir

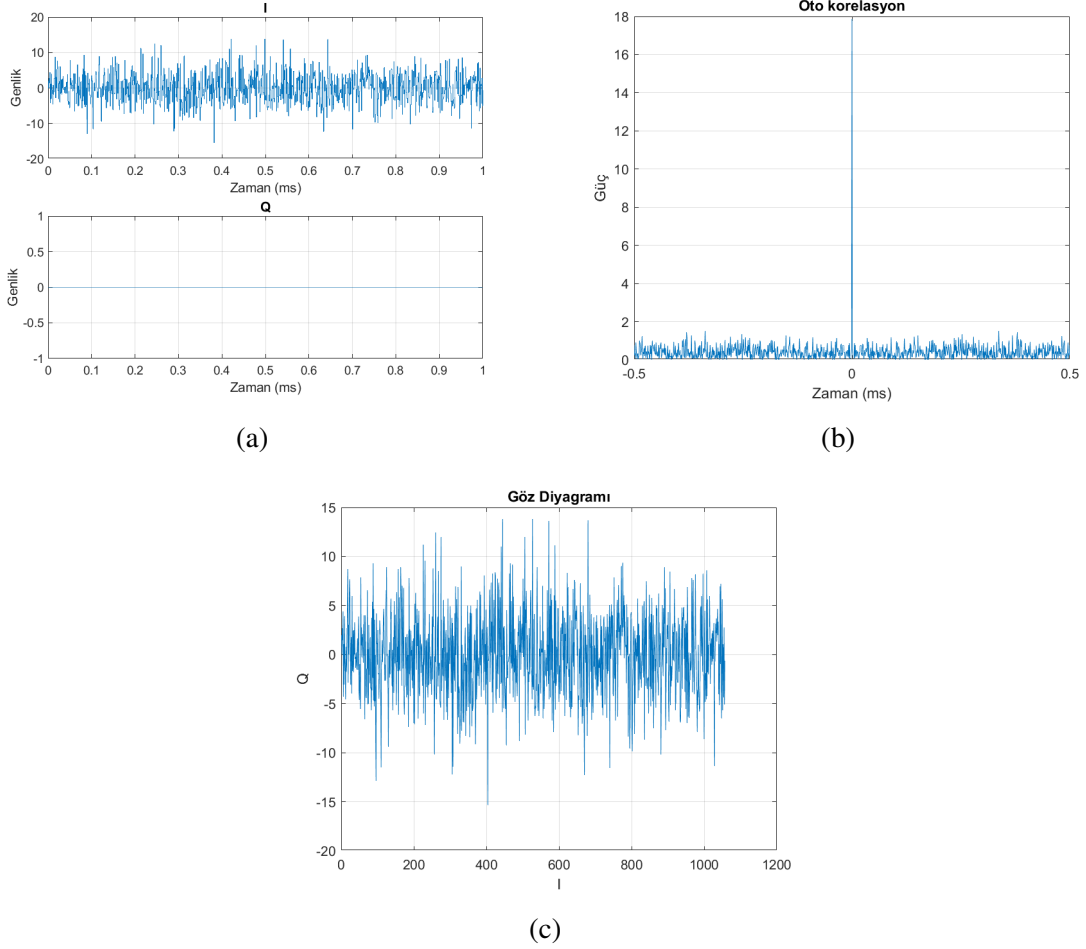
korelasyona sahip olduđu gör÷lmektedir.

Göz diyagramı analizinde ise 1-0 örneklerin etkisi ve herhangi bir bozulmanın olmadığı gör÷lmektedir.

4.1.2. Karıştırıcı İçermeyen Ancak Gürültü İçeren GNSS Sinyali

$$r(t) = s(t) + n(t) \quad (4.1.3)$$

Eşitlik 4.1.3 baz alınarak oluşturulan ve SNR değeri -12.2 dB olacak şekilde gürültü içeren GNSS sinyaline ait örnek grafikler Şekil 4.1.2’de verilmiştir.



Şekil 4.1.2: Karıştırıcı İçermeyen Ancak Gürültü İçeren GNSS Sinyal Analizleri

Üretilen sinyalin gerçek kısımları gürültünün genliğinden etkilenmiş ve bozularak yaklaşık +15/-15 değerleri arasında düzensiz bir hal almıştır.

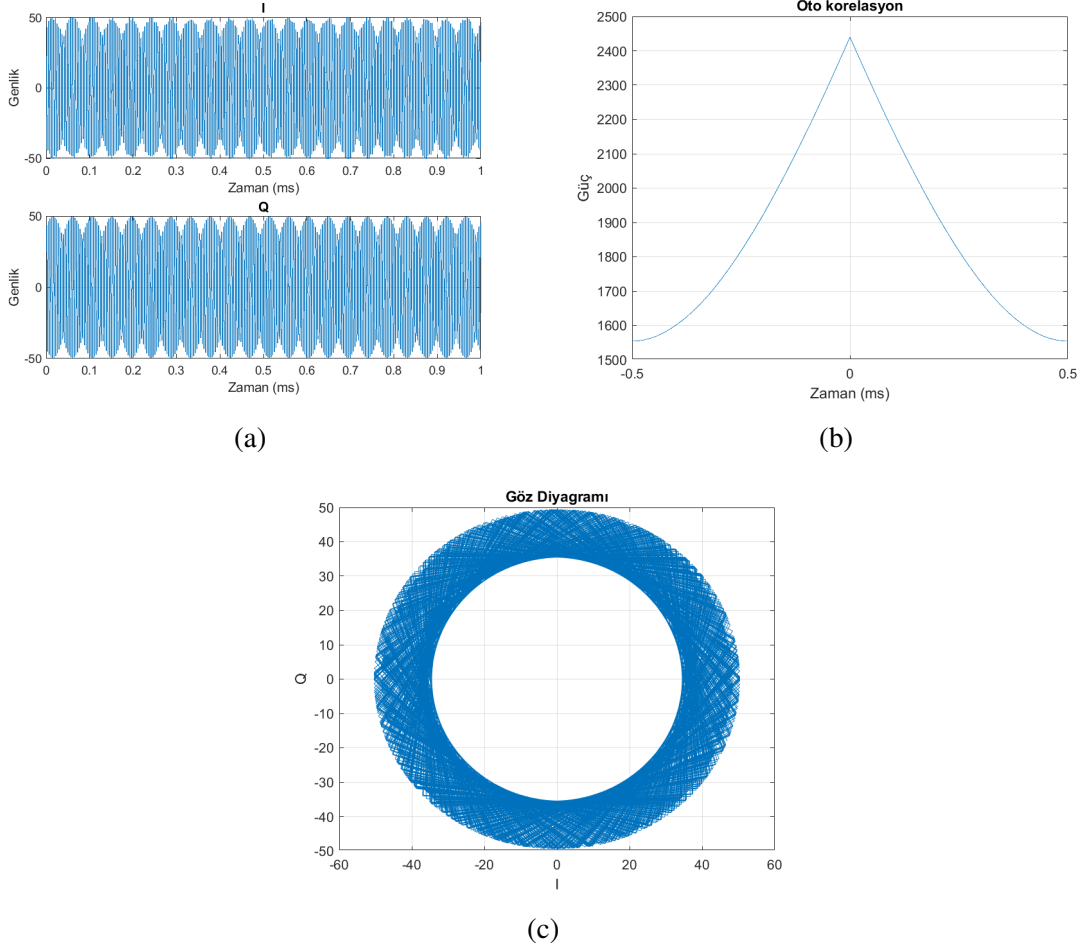
Sinyalin otokorelasyon analizinde güç değeri yine gürültünün gücünden etkilenerek yalnızca $t = 0$ anında yaklaşık 15 değerini alacak bir korelasyona sahip olduğu görülmektedir.

Göz diyagramı analizinde ise önemli bir bozulmanın varlığı görülmektedir. Bozulma gürültünün varlığına işaret etmektedir.

4.1.3. AM Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyali

$$r(t) = s(t) + j(t) \quad (4.1.4)$$

Şekil 4.1.3’de frekansı 1.8 MHz, gücü 2441 Watt, faz açısı 2.6 radyan olan bir AM karıştırıcı sinyali oluşturulmuş ve GNSS sinyaline eklenmiştir. Gürültü bulunmamaktadır.



Şekil 4.1.3: AM Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyal Analizleri

Üretilen sinyalin gerçek ve kompleks kısımları karıştırmanın genliğinden etkilenerek 50 ile -50 arasında bir değer almıştır. Ancak düzenli form korunmuştur.

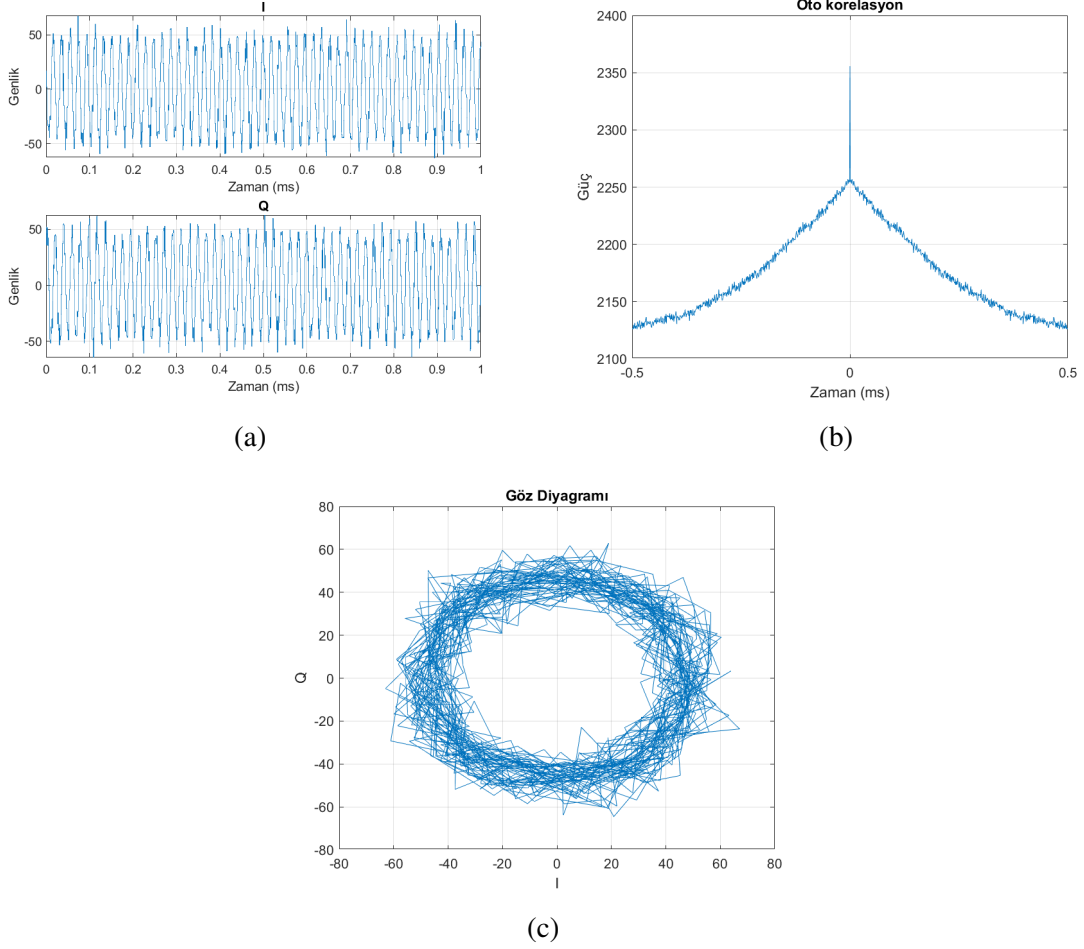
Sinyalin otokorelasyon analizinde sinyalin farklı zamanlardaki değerleri arasındaki korelasyonun arttığı görülmektedir.

Göz diyagramı analizinin ise düzenli olduğu, geçiş titreşimleri, zamanlama hassasiyeti ve gürültü marjı gibi bozucu etkilerin yokluğu dikkat çekmektedir.

4.1.4. AM Karıştırıcı ve Gürültü İçeren GNSS Sinyali

$$r(t) = s(t) + n(t) + j(t) \quad (4.1.5)$$

Şekil 4.1.4’de frekansı 6.4 MHz, gücü 2209 Watt, faz açısı 1 radyan olan bir AM karıştırıcı sinyali oluşturulmuş ve GNSS sinyaline eklenmiştir. Buna ek olarak SNR değeri -20 dB olacak şekilde gürültü eklenmiştir.



Şekil 4.1.4: AM Karıştırıcı ve Gürültü İçeren GNSS Sinyal Analizleri

Üretilen sinyalin gerçek ve kompleks kısımları hem karıştırmanın hem de gürültünün genliğinden etkilenmiştir. Sinyalin otokorelasyon analizinde sinyalin farklı zamanlardaki değerleri arasında artan korelasyonun güç seviyesinin gürültü etkisiyle azaldığı ve birebir korelasyonun zorluğu nedeniyle korelasyon grafiğinde titreşimler meydana geldiği görülmektedir.

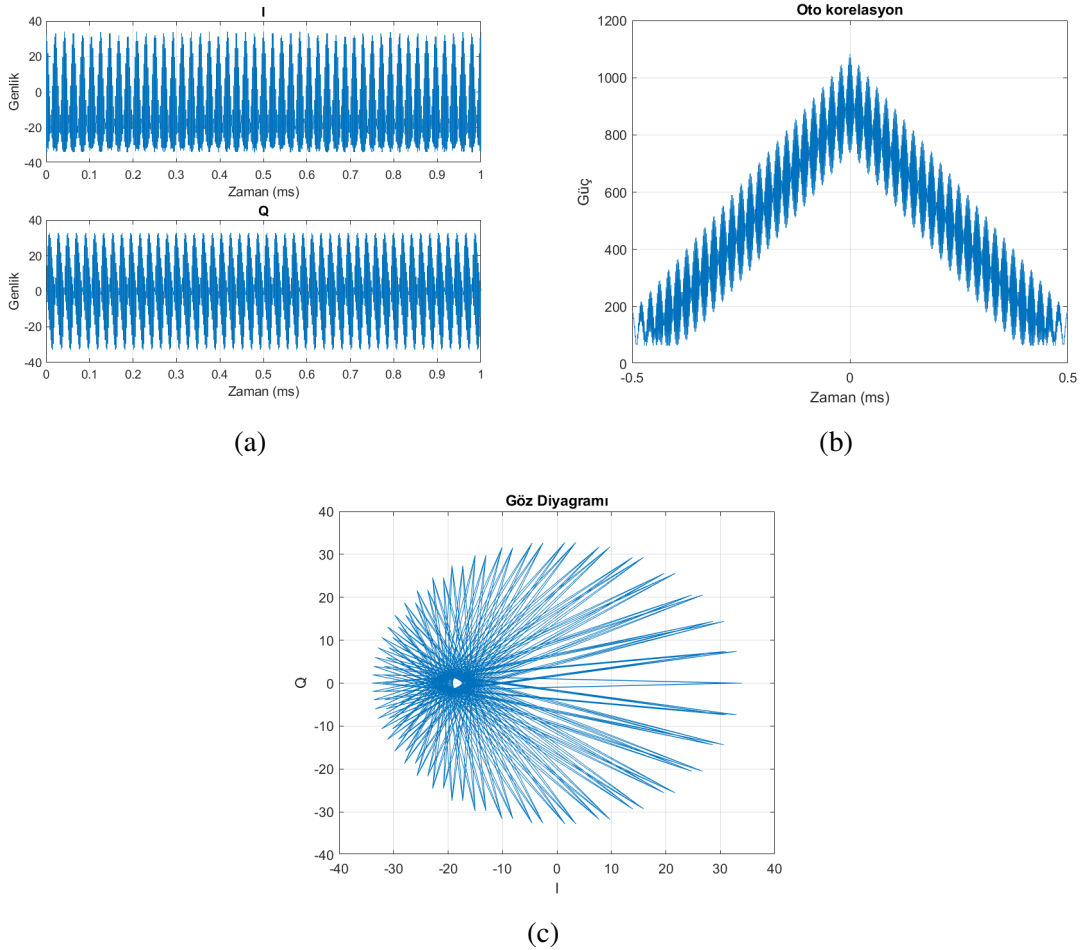
Göz diyagramı analizinin ise düzenli yapısının bozulduğu, geçiş titreşimlerinin ve sapmaların arttığı, gürültü marjının etkisini gösterdiği dikkat çekmektedir.

AM karıştırıcı sinyal tipine ait güç değerleri 100 ile 10.000 Watt arasında, frekans değerleri 0.1 MHz ile 10 MHz arasında, faz açısı değerleri 0 ile 2π radyan arasında rastgele dağılacak şekilde seçilerek GNSS sinyallerine eklenmektedir. Gürültü ise SNR değeri 0 ile -45 dB arasında olacak şekilde rastgele belirlenmektedir. Bu parametreler kullanılarak AM karıştırıcıya ve gürültüye sahip 10.000 adet GNSS sinyalinin oluşturulması sağlanmaktadır.

4.1.5. FM Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyali

$$r(t) = s(t) + j(t) \quad (4.1.6)$$

Şekil 4.1.5’de frekansı 9 MHz, gücü 1081 Watt olan, modülasyon değeri 0.59 olan bir FM karıştırıcı sinyali oluşturulmuş ve GNSS sistemine eklenmiştir. Gürültü bulunmamaktadır.



Şekil 4.1.5: FM Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyal Analizleri

Üretilen sinyalin gerçek ve kompleks kısımları karıştırmanın genliğinden etkilenerek yaklaşık 35 ile -35 arasında bir değer almıştır. Ancak düzenli form korunmuştur.

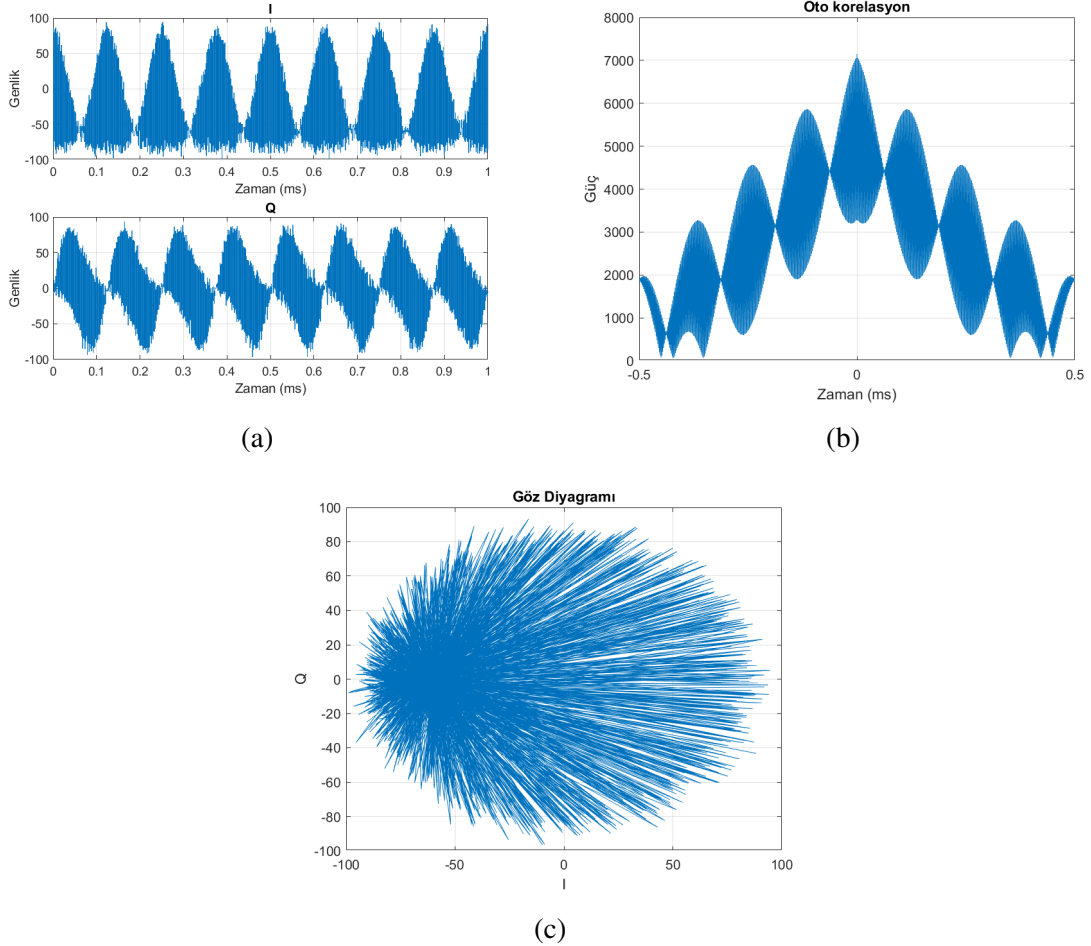
Sinyalin otokorelasyon analizinde sinyalin farklı zamanlardaki değerleri arasındaki korelasyonun arttığı ve bant genişliğinde korelasyon sağlanabildiği görülmektedir.

Göz diyagramı analizinin ise düzenli olduğu, karıştırıcının etkisi nedeniyle reel kısımda yoğunluğun daha yüksek olduğu dikkat çekmektedir.

4.1.6. FM Karıştırıcı ve Gürültü İçeren GNSS Sinyali

$$r(t) = s(t) + n(t) + j(t) \quad (4.1.7)$$

Şekil 4.1.6'de frekansı 3.7 MHz, gücü 7103 Watt olan, modülasyon değeri 0.79 olan bir FM karıştırıcı sinyali oluşturulmuş ve GNSS sinyaline eklemiştir. Buna ek olarak SNR değeri -17.8 dB olacak şekilde gürültü eklenmiştir.



Şekil 4.1.6: FM Karıştırıcı ve Gürültü İçeren GNSS Sinyal Analizleri

Üretilen sinyalin gerçek ve kompleks kısımları hem karıştırmanın hem de gürültünün genliğinden etkilenmiştir.

Sinyalin otokorelasyon analizinde sinyalin farklı zamanlardaki deęerleri arasında artan korelasyonun çözünlüęünün azaldığı görölmektedir.

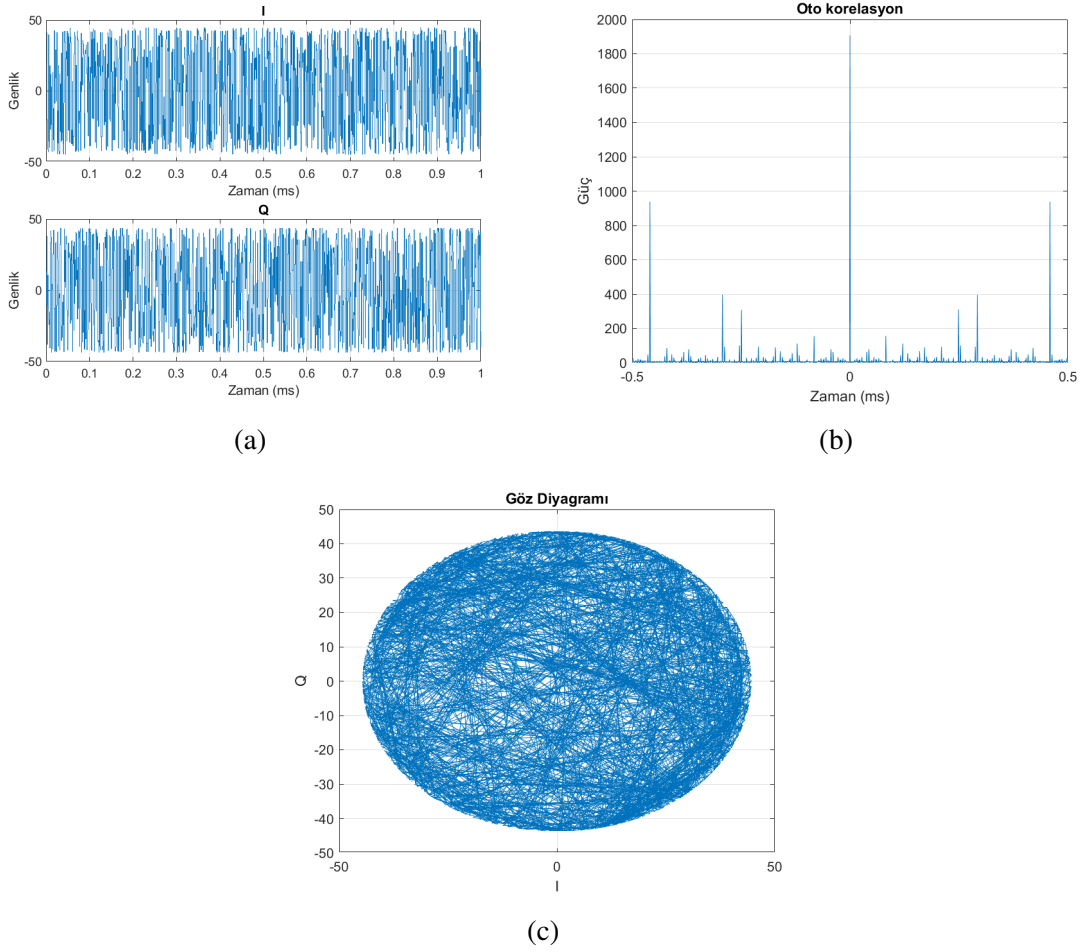
Göz diyagramı analizinin ise düzenli yapısının bozulduğu, saçılmanın arttığı, gürültü marjının etkisini gösterdiği dikkat çekmektedir.

FM karıştırıcı sinyal tipine ait güç deęerleri 100 ile 10.000 Watt arasında, frekans deęerleri 0.1 MHz ile 10 MHz arasında, modülasyon deęeri 0.5 ile 1 arasında rastgele dağılacak şekilde seçilerek GNSS sinyallerine eklenmektedir. Gürültü ise SNR deęeri 0 ile -45 dB arasında olacak şekilde rastgele belirlenmektedir. Bu parametreler kullanılarak FM karıştırıcıya ve gürültüye sahip 10.000 adet GNSS sinyalinin oluşturulması sağlanmaktadır.

4.1.7. Chirp Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyali

$$r(t) = s(t) + j(t) \quad (4.1.8)$$

Şekil 4.1.7’de frekansı 6.6 MHz olan, gücü 1904 Watt olan, sinyal yönü -1 olan, faz açısı 0.3 radyan olan bir Chirp karıştırıcı sinyali oluşturulmuş ve GNSS sinyaline eklenmiştir. Gürültü bulunmamaktadır.



Şekil 4.1.7: Chirp Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyal Analizleri

Üretilen sinyalin gerçek ve kompleks kısımları karıştırmanın genliğinden etkilenecek şekilde 50 ile -50 arasında bir değer almıştır. Ancak düzenli form korunmuştur.

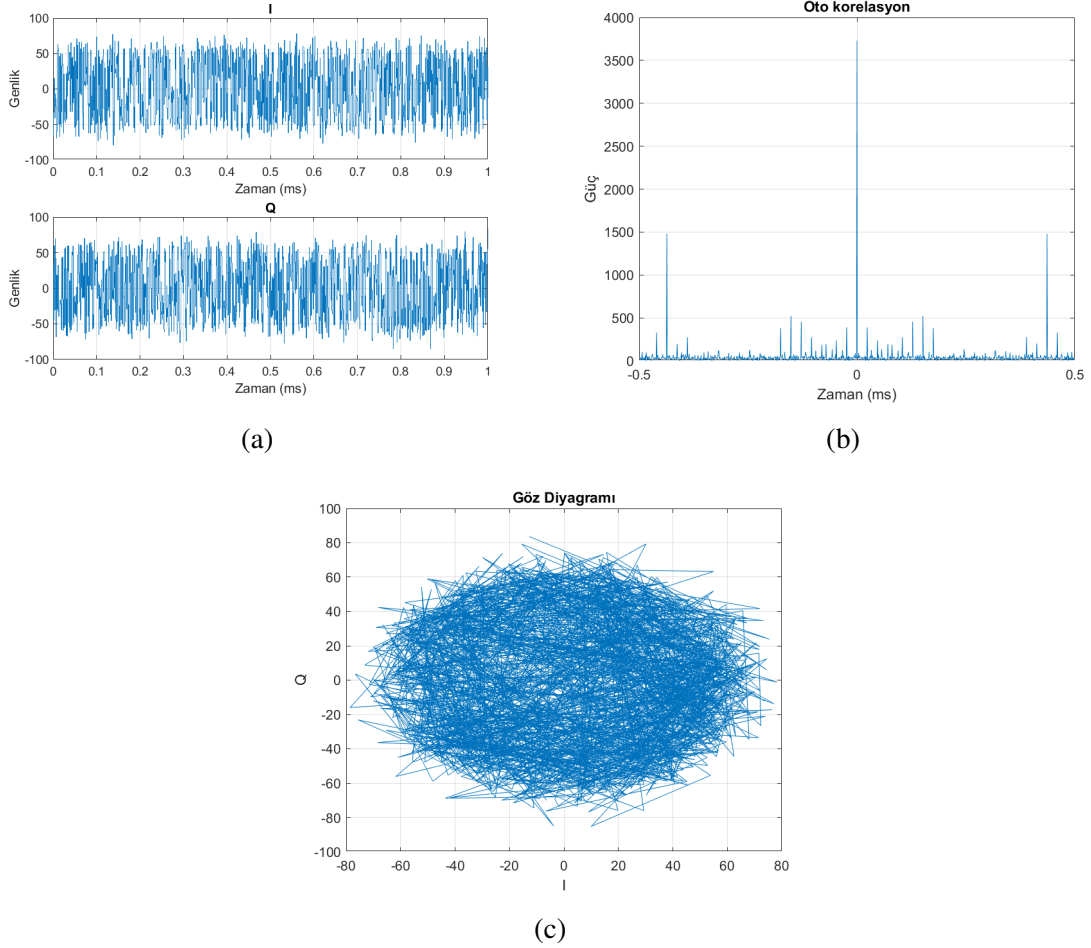
Sinyalin otokorelasyon analizinde chirp karıştırıcının GNSS sinyali üzerinde süpürme yapacak şekilde oluşturduğu etki nedeniyle otokorelasyon performansının sürekliliğini olmadığı ancak darbelerin sayısının karıştırıcı olmayan duruma kıyasla arttığı görülmektedir. Değişken zamanlarda ve değişken güçlere sahip darbe sinyaller, korelasyonların o anlarda sağlanabildiğini ifade etmiştir.

Göz diyagramı analizinin ise düzenli olduğu, geçiş titreşimleri, zamanlama hassasiyeti ve gürültü marjı gibi bozucu etkilerin yokluğu dikkat çekmektedir.

4.1.8. Chirp Karıştırıcı ve Gürültü İçeren GNSS Sinyali

$$r(t) = s(t) + n(t) + j(t) \quad (4.1.9)$$

Şekil 4.1.8’de frekansı 9 MHz olan, gücü 3621 Watt olan, sinyal yönü -1 olan, faz açısı 2.66 radyan olan bir Chirp karıştırıcı sinyali oluşturulmuş ve GNSS sinyaline eklenmiştir. Buna ek olarak SNR değeri -21.5 dB olacak şekilde gürültü eklenmiştir.



Şekil 4.1.8: Chirp Karıştırıcı ve Gürültü İçeren GNSS Sinyal Analizleri

Üretilen sinyalin gerçek ve kompleks kısımları hem karıştırmanın hem de gürültünün genliğinden etkilenmiştir.

Sinyalin otokorelasyon analizinin performansının gürültü etkisiyle daha da düştüğü görülmektedir. Belirli anlarla görülen darbe şeklindeki otokorelasyon çıktılarının bir kısmı kaybolmuştur.

Göz diyagramı analizinin ise düzenli yapısının bozulduğu, saçılmanın arttığı, gürültü marjının etkisini gösterdiği dikkat çekmektedir.

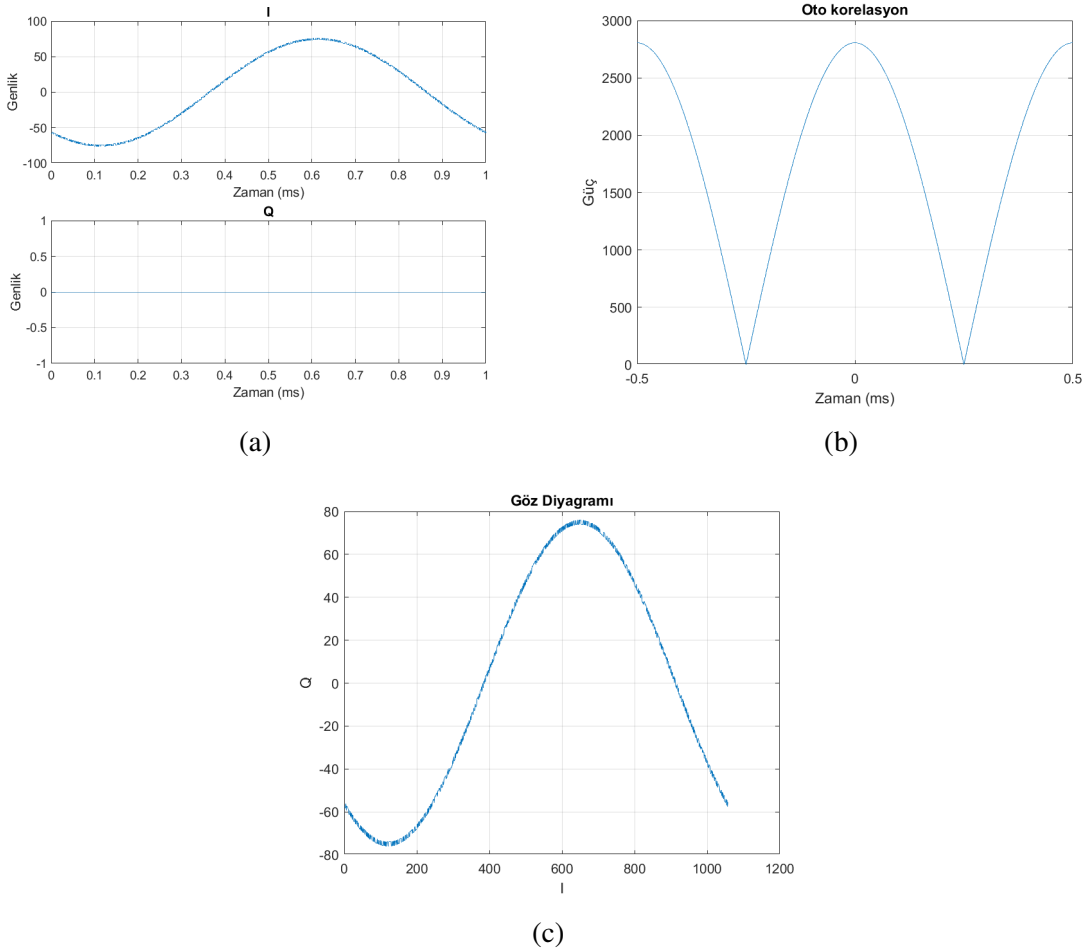
Chirp karıştırıcı sinyal tipine ait güç değerleri 100 ile 10.000 Watt arasında, frekans değerleri 5 MHz ile 20 MHz arasında, faz açısı 0 ile 2π arasında ve zaman-testere dışı değeri

$500e^{-8} - 2000e^{-8}$ arasında rastgele dağılacak şekilde seçilerek GNSS sinyallerine eklenmektedir. Gürültü ise SNR değeri 0 ile -45 dB arasında olacak şekilde rastgele belirlenmektedir. Bu parametreler kullanılarak Chirp karıştırıcıya ve gürültüye sahip 10.000 adet GNSS sinyalinin oluşturulması sağlanmaktadır.

4.1.9. NB Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyali

$$r(t) = s(t) + j(t) \quad (4.1.10)$$

Şekil 4.1.9'de frekansı 107.4 MHz olan, gücü 5617 Watt olan, faz açısı 2.43 radyan olan bir NB karıştırıcı sinyali oluşturulmuş ve GNSS sinyaline eklenmiştir. Gürültü bulunmamaktadır.



Şekil 4.1.9: NB Karıştırıcı İçeren Ancak Gürültü İçermeyen GNSS Sinyal Analizleri

Üretilen sinyalin gerçek ve kompleks kısımları karıştırmanın genliğinden etkilenerek yaklaşık 75 ile -75 arasında bir değer almıştır. Genlik grafiği NB karıştırıcının etkisiyle sinüsoidal

bir forma girmiştir. Ancak düzenli form korunmuştur.

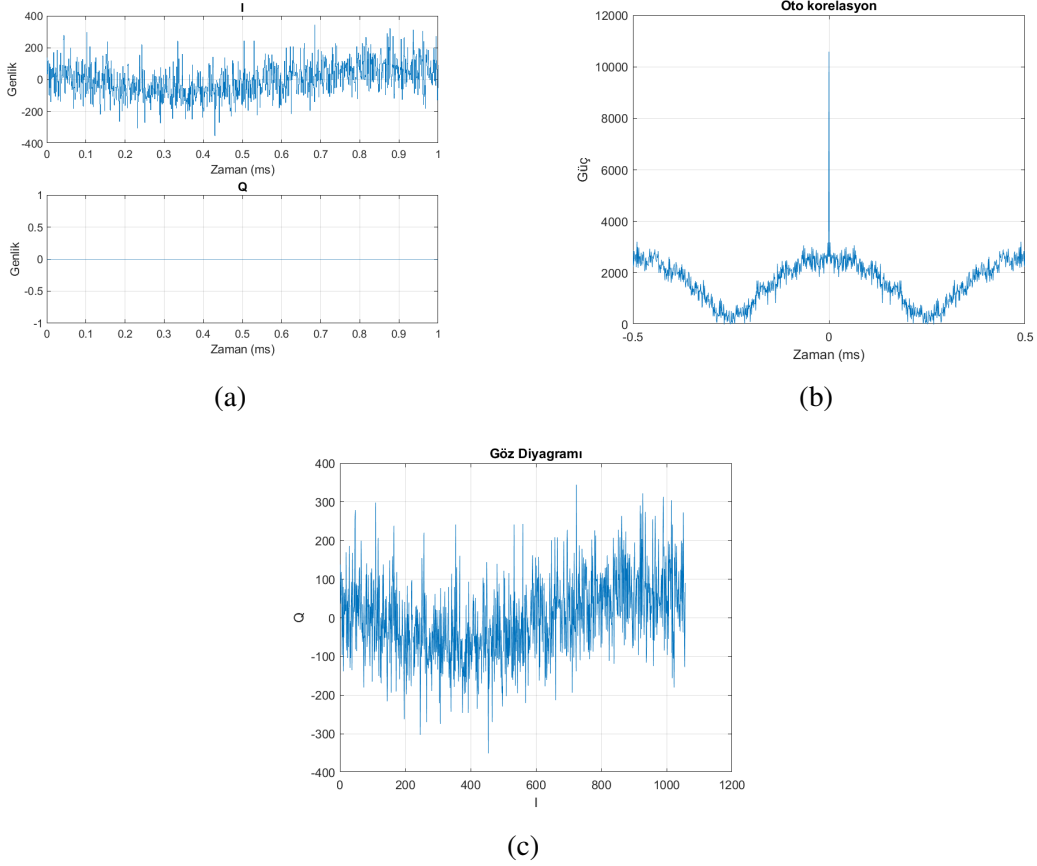
Sinyalin otokorelasyon analizinde NB karıştırıcının GNSS sinyali üzerinde yarattığı dar banttaki etki nedeniyle otokorelasyon performansının sürekliliğinin karıştırıcı sinyalin bitti anlarda kaybolduğu, başladığı anlarda yeniden sağlandığı görülmektedir. $t = 0$ anında saf GNSS sinyalinin sahip olduğu korelasyon özelliğinin de korunduğu gözlenmiştir.

Göz diyagramı analizinin ise diğer karıştırıcı türlerinden farklı şekilde sinüsoidal bir yapıda olduğu ancak düzenli olduğu anlaşılmıştır.

4.1.10. NB Karıştırıcı ve Gürültü İçeren GNSS Sinyali

$$r(t) = s(t) + n(t) + j(t) \quad (4.1.11)$$

Şekil 4.1.10'de frekansı 490 MHz olan, gücü 4763 Watt olan, faz açısı 0.92 radyan olan bir NB karıştırıcı sinyali oluşturulmuş ve GNSS sinyaline eklenmiştir. Buna ek olarak SNR değeri -38.9 dB olacak şekilde gürültü eklenmiştir.



Şekil 4.1.10: NB Karıştırıcı ve Gürültü İçeren GNSS Sinyal Analizleri

Üretilen sinyalin gerçek ve kompleks kısımları hem karıştırmanın hem de gürültünün genliğinden etkilenmiştir.

Sinyalin otokorelasyon analizinin performansının gürültü etkisiyle daha da düştüğü görülmektedir. Sinyalin otokorelasyon analizinde sinyalin farklı zamanlardaki değerleri arasında artan korelasyon güç seviyesinin gürültü etkisiyle azaldığı korelasyon grafiğinde titreşimler meydana geldiği görülmektedir.

Göz diyagramı analizinin ise düzenli yapısının bozulduğu, saçılmanın arttığı, gürültü marjının etkisini gösterdiği dikkat çekmektedir.

NB karıştırıcı sinyal tipine ait güç değerleri 100 ile 10.000 Watt arasında, frekans değerleri 20 MHz ile 2.000 MHz arasında, faz açısı 0 ile 2π arasında rastgele dağılacak şekilde seçilerek GNSS sinyallerine eklenmektedir. Gürültü ise SNR değeri 0 ile -45 dB arasında olacak şekilde rastgele belirlenmektedir. Bu parametreler kullanılarak NB karıştırıcıya ve gürültüye sahip 10000 adet GNSS sinyalinin oluşturulması sağlanmaktadır.

Gürültü içeren ancak karıştırıcı içermeyen GNNS sinyali, AM karıştırıcı ve gürültü içeren GNNS sinyali, FM karıştırıcı ve gürültü içeren GNNS sinyali, Chirp karıştırıcı ve gürültü içeren GNNS sinyali, NB karıştırıcı ve gürültü içeren GNNS sinyali olmak üzere 5 farklı sınıf için her bir data setine ait 10000 veri olmak üzere toplamda 50000 sinyal üretimi gerçekleştirilerek her GNNS sinyali için öznitelik çıkarım işlemi gerçekleştirilmektedir.

4.2. Öznitelik Çıkarımı

Elde edilen karıştırılmış ve gürültü eklenmiş $r(t)$ sinyalinin belirlenen makine öğrenmesi modellerine sokulmadan önce özniteliklerinin çıkarılması işlemi yapılmıştır. Öznitelik çıkarma için Kısa Zamanlı Fourier Dönüşüm (STFT) ve Wigner-Ville yöntemleri tercih edilmiştir. Kısa zamanlı Fourier dönüşüm yöntemi, ifade edilen karıştırıcı türlerinin zaman-frekans analizleri için hem iyi çözünürlük hem de düşük karmaşıklık sağlamaya odaklanmış bir parametre seçimiyle yürütülür. Wigner-Ville yöntemi için de temel kaygı benzerdir.

İki yöntem ayrı ayrı uygulayarak 1057×1 matrisler olarak elde edilen sonuçlar öğrenme modellerine girdi olarak sağlanmıştır. Öğrenme performansları kıyaslanarak hangi öznitelik çıkarma yönteminin diğerine oranla daha başarılı olduğu, makine öğrenmesi tipine bağlı olarak gösterilmiştir. Ayrıca öznitelik çıkarmadan, $r(t)$ sinyalinin kendisiyle de öğrenme algoritmaları test edilmiş ve sonuçları verilmiştir. Öznitelik varlığında ya da yokluğunda makine öğrenmesi yöntemlerinin performansları da bu veriler ışığında değerlendirilmiştir.

4.2.1. Kısa Zamanlı Fourier Dönüşüm - STFT

Kısa zamanlı Fourier dönüşüm düşük karmaşıklık, düşük işlem yükü ve iyi çözünürlük sağladığı gerekçesiyle benzer problemlerin çözümü için sıklıkla tercih edilmektedir. Bizim problemimizde ise bazı karıştırıcılar durağan olmadığından (chirp karıştırıcı gibi) STFT'nin en iyi zaman-frekans modelleme yöntemlerinin biri olabileceği değerlendirilmiştir.

Matlab Signal Toolbox üzerinden spectrogram methodu kullanılarak öznitelik çıkarım işlemi

1057x1 büyüklüğünde sinyallerin kullanılmasıyla gerçekleştirilmiştir. Bu işlem 1 ms süreli üretilen 50000 sinyalin tamamı için uygulanmıştır. Sinyallerin analizi için 128 örneklilik bir pencere tercih edilmiştir. Böylece 128 numunelik bir hızlı Fourier dönüşüm (FFT) boyutu elde edilmiştir. Sistem seçilen bu pencere genişliği ile örnekleme frekansı 1057 MHz olan her sinyalde 120 örnekle örtüşme sağlamaktadır. Bunun sonucunda 117x128 boyutunda öz-nitelik matrisleri elde edilmiştir. Elde edilen öznelik matrisleri karıştırma olmayan ve dört ayrı karıştırma türü uygulanan durumu ifade etmek amacıyla 0-1-2-3-4 olarak etiketlenen etiketlere bağlanmıştır. Eğitim seti bu şekilde oluşturulmuştur.

Bu spectrogram'lar çizdirildiğinde elde edilen görüntüler Şekil 4.2.1 ile Şekil 4.2.5 arasındaki görsellerde farklı karıştırma tipleri için sırasıyla verilmiştir.

4.2.2. Wigner-Ville Dağılımı

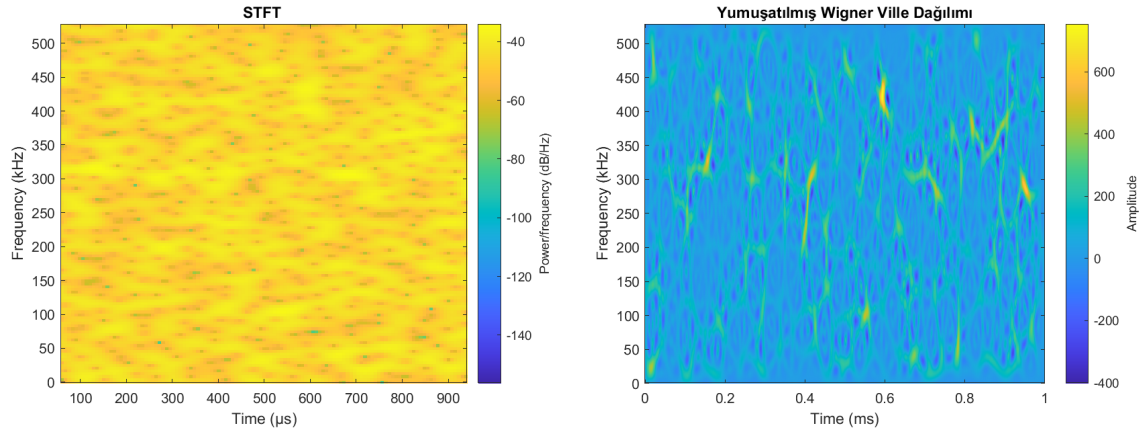
Wigner-Ville dağılımı yüksek karmaşıklık içeren, işleme yükü yüksek olan bir zaman-frekans analiz yöntemi olmasına karşın sağladığı çok yüksek çözünürlüğün öğrenme sürecinde göstereceği etki analiz edilmek istenmiştir. Çözünürlüğün yüksek olmasının performansta beklenen pozitif etkiyi gösterip göstermediği test edilmiştir. Oluşturulan 1057x1 büyüklükte 50000 sinyal öznelik çıkarımı için Wigner-Ville algoritmalarına sokulmuştur. Ancak Wigner-Ville yönteminin bazı çapraz istenmeyen girişimler içermesi nedeniyle Yumuşatılmış Wigner-Ville yöntemi kullanılması tercih edilmiştir. Seçilen zaman ve frekans filtreleri h ve g ile ifade edilen Hamming pencereleme yöntemi uygulanmış ve Yumuşatılmış Wigner-Ville yaklaşımı elde edilmiştir. Matlab Wavelet Toolbox üzerinden wvd methodu kullanılarak öznelik çıkarım işlemi gerçekleştirilmiştir. Bu işlem özelinde tüm sinyaller 'SmoothedPseudo' olarak ele alınmıştır.

Bunu işlem sonucunda her sinyal için 1058x2116 boyutunda öznelik matrisleri elde edilmiştir. Elde edilen matrisin boyutu yüksek detay ve çözünürlük sağladığı için çok büyüktür. Üretilen her öznelik matrisinin boyutunun STFT ile üretilen öznelik matrislerine kıyasla yaklaşık 150 kat daha büyük olduğu görülmüştür.

Yumuşatılmış Wigner-Ville dağılımı ile spectrogram'lar çizdirildiğinde elde edilen görüntüler yine Şekil 4.2.1 ile Şekil 4.2.5 arasındaki görsellerde farklı karıştırma tipleri için sırasıyla verilmiştir.


Bu iki yöntem kıyaslandığında Wigner-Ville'in sinyal analizi gerçekleştirirken daha çok de-

tay içerdiği için analiz sonucu elde edilen verinin daha büyük bir boyutta olduğu ve daha uzun sürdüğü görülmüştür.



Şekil 4.2.1: Karıştırıcı İçermeyen GNSS Sinyali Spektral Analizi

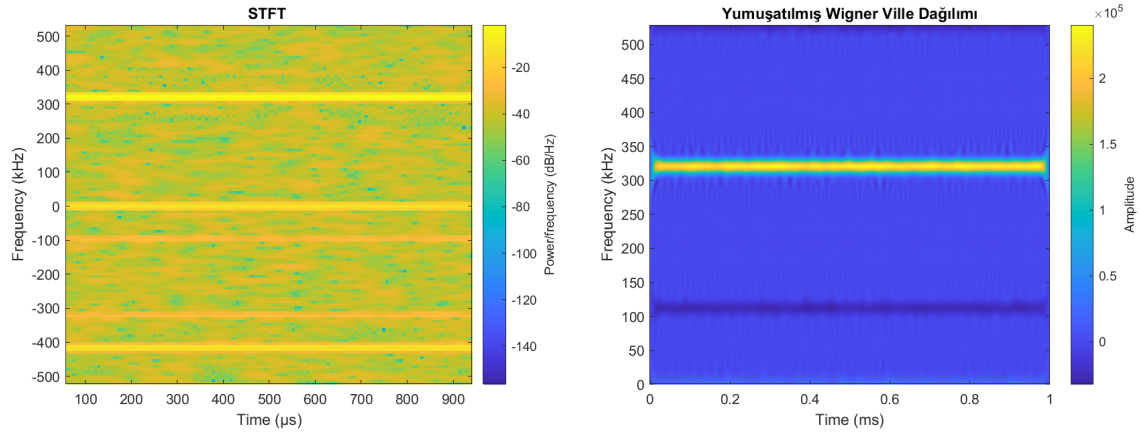
Karıştırıcı içermeyen spektrum grafiklerinde kısa zamanlı Fourier dönüşüm ve yumuşatılmış Wigner-Ville dağılımı sonuçlarında yalnızca gürültünün normal dağılmış görüntüsü dikkat çekmektedir.



Şekil 4.2.2: AM Karıştırıcı İçeren GNSS Sinyali Spektral Analizi

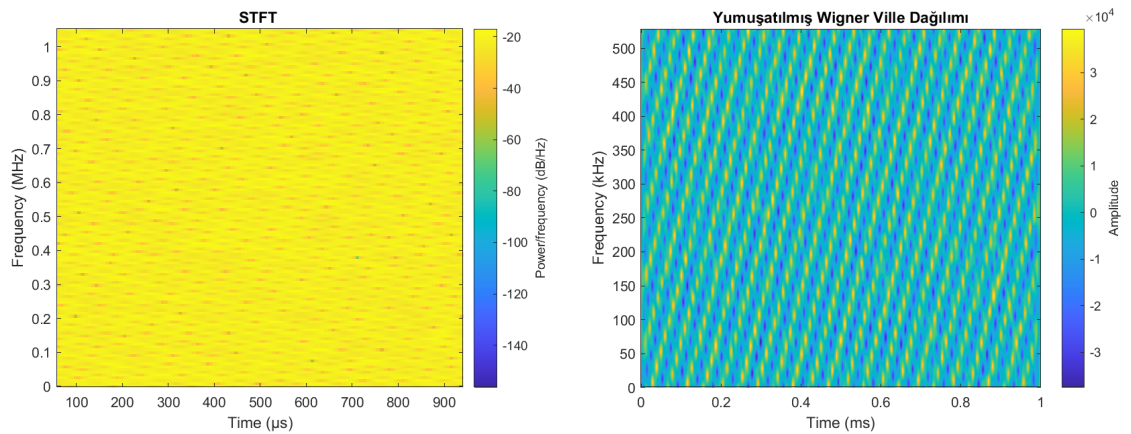
AM karıştırıcı içeren spektrum grafiklerinde kısa zamanlı Fourier dönüşüm ve yumuşatılmış Wigner-Ville dağılımı sonuçları her ikisi için de aynı sinyal için incelendiğinde belirli bir frekans değerinde belirgin bir karıştırma etkisinin varlığını ayırt edebilmiştir. Yumuşatılmış Wigner-Ville ile çıkarılan spektrum analizinde görülen belirgin şeridin etrafında oluşan detaylar, daha düz bir çizgi şeklinde görsel oluşturan kısa zamanlı Fourier dönüşüm grafikleriyle kıyaslandığında Wigner-Ville'nin daha yüksek çözünürlüğe sahip olduğunu bir kez daha göstermektedir. Yumuşatılmış Wigner-Ville ayrıca karıştırıcı etkisini tespit ederken or-

tamda bulunan sinyalin ya da gürültünün enerjisinden daha az etkilenmiş ve karıştırıcıya dair öznitelikleri daha belirgin şekilde ortaya çıkarmıştır.



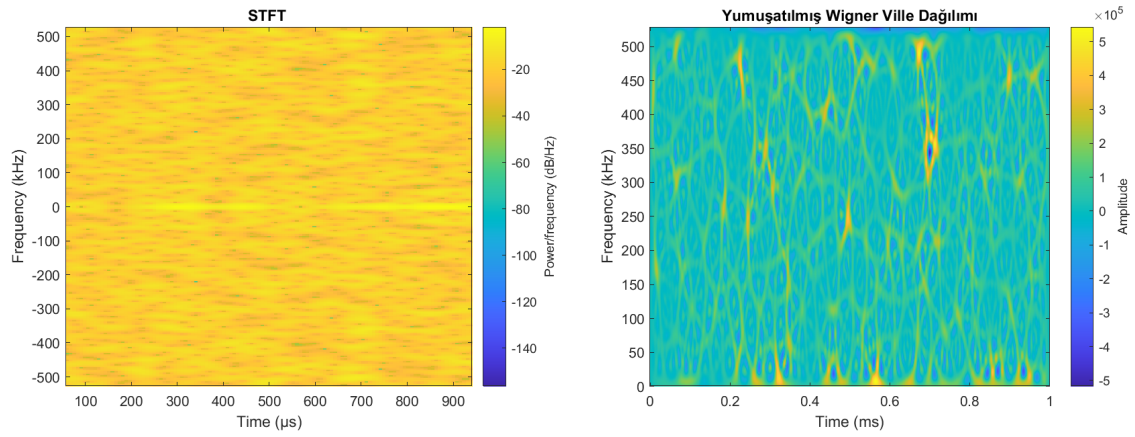
Şekil 4.2.3: FM Karıştırıcı İçeren GNSS Sinyali Spektral Analizi

FM karıştırıcı içeren spektrum grafiklerinde kısa zamanlı Fourier dönüşüm ve yumuşatılmış Wigner-Ville dağılımı sonuçları her ikisi için de aynı sinyal için incelendiğinde belirli frekans değerlerinde belirgin bir karıştırma etkisinin varlığını ayırt edebilmiştir. Yumuşatılmış Wigner-Ville ile çıkarılan spektrum analizinde görülen belirgin şeridin etrafında oluşan detaylar, daha düz bir çizgi şeklinde görsel oluşturan kısa zamanlı Fourier dönüşüm grafikleriyle kıyaslandığında Wigner-Ville'nin daha yüksek çözünürlüğe sahip olduğunu bir kez daha göstermektedir. Yumuşatılmış Wigner-Ville ayrıca karıştırıcı etkisini tespit ederken ortamda bulunan sinyalin ya da gürültünün enerjisinden daha az etkilenmiş ve karıştırıcıya dair öznitelikleri daha belirgin şekilde ortaya çıkarmıştır. Ancak Yumuşatılmış Wigner-Ville üzerinde uygulanan filtreler nedeniyle bazı değerlerdeki frekans etkilerine dair öznitelikleri ayırt edebilmekte zorlanmıştır.



Şekil 4.2.4: Chirp Karıştırıcı İçeren GNSS Sinyali Spektral Analizi

Chirp karıştırıcı içeren spektrum grafiklerinde kısa zamanlı Fourier dönüşüm ve yumuşatılmış Wigner-Ville dağılımı sonuçları her ikisi için de aynı sinyal için incelendiğinde belirli bir frekans değerinde belirgin bir taramanın varlığıyla karıştırma etkisini ayırt edebilmiştir. Yumuşatılmış Wigner-Ville ile çıkarılan spektrum analizinde görülen belirgin örüntülerin etrafında oluşan detaylar kısa zamanlı Fourier dönüşüm grafikleriyle kıyaslandığında daha yüksek çözümlüğe sahip olduğu birkez daha anlaşılmaktadır. Yumuşatılmış Wigner-Ville spektrum analizinde Chirp karıştırıcının ve gürültünün enerji etkisinin arttığı, AM ve FM karıştırıcılarda olduğu kadar keskin bir enerji ayırımının yapılamadığı görülmektedir. Ancak kısa zamanlı Fourier dönüşüm analizine kıyasla enerji ayırımı daha keskindir.



Şekil 4.2.5: NB Karıştırıcı İçeren GNSS Sinyali Spektral Analizi

NB karıştırıcı içeren spektrum grafiklerinde kısa zamanlı Fourier dönüşüm sonuçlarında birkaç bantta belirgin bir karıştırma etkisinin varlığı görülmektedir. Ancak Yumuşatılmış Wigner-Ville spektrogram analizlerinde bu ayırımın gözle görülemediği ancak sinyaller incelendiğinde bir örüntünün tespit edilebildiği anlaşılmıştır.

4.3. Karıştırıcı Sınıflandırma Yöntemleri

Ham sinyal ve buna ek olarak daha iyi bir sonuç elde edileceğine inanılarak STFT ve Yumuşatılmış Wigner-Ville zaman frekans yöntemleri aracılığıyla oluşturulan sinyallerden çıkarılan öznetelikler ayrı ayrı sınıf etiketleri ile birlikte kaydedilerek (NoJamming (0), AM(1), Chirp(2), FM(3), NB(4)) makine öğrenmesi algoritmaları tarafından sınıflandırılabilmesi için ".csv" dosyalarına kaydedilmektedir. Sınıflandırma problemi için makine öğrenmesi yöntemlerinden SVM, CNN, MLP, NN ve RF yöntemleri uygulanarak performans analizleri gerçekleştirilmiştir.

Makine öğrenmesi modelleri uygulanırken ham sinyalle yürütülen öğrenme süreci için 32000 veri eğitim için 8000 veri doğrulama için 10000 veri ise test için kullanılmıştır. Öznitelik çıkarımı yapılmadan 1057x1 büyüklüğünde sinyal matrisleri girdi olarak sağlanmıştır.

Makine öğrenmesi modelleri uygulanırken kısa zamanlı Fourier dönüşüm için 10000 veri eğitim için 2000 veri doğrulama için 38000 veri ise test için kullanılmıştır. Eğitim verisi sayısının artırılması özellikle SVM algoritmalarında çok uzun işlem süresi gerektirmesi nedeniyle 10000 seviyesinde tutulmuştur. 117x128 büyüklüğünde öznitelik matrisleri girdi olarak sağlanmıştır.

Makine öğrenmesi modelleri uygulanırken Yumuşatılmış Wigner-Ville için 10000 veri eğitim için 2000 veri doğrulama için 15000 veri ise test için kullanılmıştır. Eğitim verisi sayısının artırılması özellikle SVM algoritmalarında çok uzun işlem süresi gerektirmesi nedeniyle 10000 seviyesinde tutulmuştur. 2116x2 büyüklüğünde öznitelik matrisleri girdi olarak sağlanmıştır.

4.3.1. Rastgele Orman Yöntemi

Rastgele orman yönteminde Python kütüphanelerinden Sklearn kütüphanesi kullanılmış ve 200 adet karar ağacı kullanılacak şekilde algoritma tasarlanmıştır [55].

4.3.2. Destek Vektör Makineleri Yöntemi

Destek vektör makineleri yönteminde yine Python kütüphanelerinden Sklearn kütüphanesi kullanılmıştır [55]. Bu kütüphanede libsvm algoritmasından faydalanılmıştır [56]. Izgara yöntemi izlenirken en iyi performans 'poly' çekirdek tipinde elde edilmiştir. Çekirdek katsayısı 100, düzenleme parametresi 1000 olarak seçilmiştir.

4.3.3. Çok Katmanlı Algılayıcı Yöntemi

Çok katmanlı algılayıcı yönteminde yine Python kütüphanelerinden Sklearn kütüphanesi kullanılmıştır [55]. Aktivasyon fonksiyonu 'relu', düzenleme parametresi 10^{-3} ve gizli nöron sayısı 50 olarak tasarlanmıştır.

4.3.4. Sinir Ağları Yöntemi

Sinir ağı modeli tasarlanırken nöronlar arasında fazla uyumlanmayı engellemek amacıyla bir kez seyreltme işlemi uygulanmıştır. Sinir ağının ilk gizli katmanında relu aktivasyon fonksiyonuna sahip 256 nöron, ikinci gizli katmanında yine relu aktivasyon fonksiyonuna sahip 128 nöron, son olarak çıkış katmanında ise 'softmax' kullanılacak şekilde sinir ağı modeli geliştirilmiştir. Optimizasyon fonksiyonu olarak 'adam' fonksiyonu kullanılmıştır. Model 50 epok boyunca öğrenme gerçekleştirmektedir. Bu işlemler Keras kütüphanesi kullanılarak gerçekleştirilmiştir [57].

4.3.5. CNN

Evrişimli sinir ağı modeli tasarlanırken nöronlar arasında fazla uyumlanmayı engellemek amacıyla yine bir kez seyreltme işlemi uygulanmıştır. Ardından Python kütüphanelerinden TensorFlow kütüphanesi kullanılarak iki kez 'cov1D' algoritması uygulanmıştır [58]. Böylece tek bir uzaysal boyut üzerinde evrişim çekirdeği oluşturulmuştur. Çekirdek sayısı 16 olarak seçilmiştir. Elde edilen pencereler üzerinde maksimum değerlerin alınması için 'max pooling' algoritması uygulanmıştır. Elde edilen havuzlama katmanları çıktıları 'flatten' algoritmaları uygulanarak matrisler tek boyuta indirilmiştir. Gizli katmanda relu aktivasyon fonksiyonuna sahip 100 nöron kullanılmıştır. Çıkış katmanında ise softmax kullanılacak şekilde sinir ağı modeli geliştirilmiştir. Optimizasyon fonksiyonu olarak 'adam' fonksiyonu kullanılmıştır. Model 50 epok boyunca öğrenme gerçekleştirmektedir.

4.4. Karıştırıcı Sınıflandırma Analizleri

4.4.1. Ham Sinyalin Kullanılmasıyla Sınıflandırma Performansı

Ham sinyallerde öznitelik çıkarımı yapılmadan 1057x1'lik matrisler elde edilmiş ve her bir matris uygun şekilde etiketlenmiştir. Elde edilen öznitelik matrisleri sınıflandırılma algoritmaları ile eğitim ve test işlemlerine tabii tutulmuştur. Makine öğrenmesi çıktılarında aşağıdaki sonuçlar elde edilmiştir.

Çizelge 4.4.1: Ham Veri Seti Performans Analiz Çizelgesi

	Sınıf Tipi	Kesinlik	Duyarlılık	F-Skoru
CNN	NJ	1.00	1.00	1.00
	AM	1.00	1.00	1.00
	Chirp	0.86	0.73	0.79
	FM	0.76	0.88	0.81
	NB	1.00	1.00	1.00
SVM	NJ	0.99	1.00	1.00
	AM	1.00	1.00	1.00
	Chirp	0.80	0.78	0.79
	FM	0.78	0.79	0.79
	NB	1.00	1.00	1.00
RF	NJ	0.98	1.00	0.99
	AM	0.99	1.00	1.00
	Chirp	0.77	0.82	0.80
	FM	0.80	0.73	0.76
	NB	0.80	0.73	0.76

NN ve MLP algoritmaları %76 doğruluk gösterirken RF %90, SVM ve CNN %91 üzeri doğruluk oranı vermiştir. RF, SVM ve CNN'e ait performans detayları Çizelge 4.4.1'da verilmektedir. NN ve MLP algoritmaları öğrenme detayları istenen performans elde edilemediği için verilmemiştir.

CNN, en yüksek başarıyı NJ, AM ve NB durumlarını ayırmada göstermiş ve neredeyse hiç hata yapmamıştır. En düşük başarıyı ise FM ve Chirp karıştırıcıları ayırmada göstermiştir.

SVM, en yüksek başarıyı NJ, AM ve NB durumlarını ayırmada göstermiş ve neredeyse hiç hata yapmamıştır. En düşük başarıyı ise Chirp ve FM karıştırıcıları ayırmada göstermiştir.

RF, en yüksek başarıyı AM ve NJ durumlarını ayırmada göstermiş ve çok düşük hata yapmıştır. En düşük başarıyı ise FM ve Chirp karıştırıcıları ayırmada göstermiştir.

Ham verilerin makine öğrenmesi algoritmalarına verilmesiyle yürütülen sınıflandırma işlemlerinde karıştırmanın olmadığı durumu %100 doğrulukla ayırt edebilen yöntemler elde edi-

lebilmıştır. Ayrıca bu işlemlerde genel olarak AM karıştırıcısının olduğu durumları ayırt etme performansının görece diğer durumları ayırt etmeye kıyasla daha iyi performans sergilediği ifade edilebilir.

Alt olunan sınıf	NJ	2016	0	0	0	0
	AM	0	1961	0	0	0
	CHIRP	0	0	1478	550	0
	FM	3	1	243	1750	0
	NB	0	0	5	0	1993
		NJ	AM	CHIRP	FM	NB
		Tahmin edilen sınıf				

(a) CNN

Alt olunan sınıf	NJ	2029	0	0	0	0
	AM	0	1998	0	0	0
	CHIRP	0	0	1588	443	7
	FM	14	10	385	1580	0
	NB	0	0	0	0	1946
		NJ	AM	CHIRP	FM	NB
		Tahmin edilen sınıf				

(b) SVM

Alt olunan sınıf	NJ	1978	0	0	0	0
	AM	0	2015	0	0	0
	CHIRP	0	0	1664	354	0
	FM	46	11	480	1432	0
	NB	0	0	20	0	2000
		NJ	AM	CHIRP	FM	NB
		Tahmin edilen sınıf				

(c) RF

Şekil 4.4.1: Ham Veri Seti Karışıklık Matrisi

Ham sinyallerin kullanılmasıyla makine öğrenmesi yöntemleriyle sınıflandırma işlemlerinde en uygun modelin CNN ve SVM olduğu görülmektedir. CNN modelinin işlem hızının SVM ile kıyaslandığında daha düşük olması ve karıştırma olmayan durumu ifade eden NJ durumu tam kesinlikle ayırt edebilmesi CNN yöntemini SVM yönteminin önüne geçirmektedir. Ham veriyle yürütülen sınıflandırma problemlerinde CNN kullanılması en iyi çözüm olarak görülmektedir.

Chirp ve FM karıştırıcıların ayırt edilmesinde ham verilerle yürütülen sınıflandırma faaliyetlerinin Şekil 4.4.1’de görüleceği üzere düşük performansa sahip olması ve NN ile MLP makine öğrenmesi yöntemlerinin performanslarının çok düşük olması aynı işlemlerin öznelikler çıkarılarak yapılması yaklaşımının gelişmesine neden olmuştur.

NN ve MLP gürültü içeren ham veri ile iyi bir performans sergileyememiştir. SVM modeli yapısal riskin modernizasyonuna dayanırken MLP sınıflandırıcılar girdi olarak bir vektörü alır ve ampirik risk minimizasyonu mantığıyla hareket eder. Bu nedenle SVM daha önce

bilinmeyen verilerin doğru sınıflandırılmasında daha iyi performans sergilemeye daha yatkındır. CNN ise girdi olarak tensörü alır. Böylece sinyaller arasındaki uzamsal ilişkiyi daha iyi algılar. Böylece karmaşık problemlerde daha iyi bir performans sergilemeye yatkındır. RF modelinde ise hatalı her karar birçok karar ağacı tarafından oylandığı için hataları kararların baskın gelmesi riski indirgenmiştir. MLP ve NN yöntemlerine kıyasla ham verilerle yürütülen öğrenme süreçlerinde RF, SVM ve CNN modellerinin daha yüksek başarıya sahip olmasının sebepleri bu şekilde yorumlanmıştır.

4.4.2. STFT Uygulanarak Çıkarılan Özniteliklerin Kullanılmasıyla Sınıflandırma Performansı

STFT kullanılarak çıkarılan özniteliklerden 128x117'lik matrisler elde edilmiş ve her bir matris uygun şekilde etiketlenmiştir. Elde edilen öznitelik matrisleri sınıflandırılma algoritmaları ile eğitim ve test işlemlerine tabii tutulmuştur. Makine öğrenmesi çıktılarında aşağıdaki sonuçlar elde edilmiştir.

Çizelge 4.4.2: STFT Veri Seti Doğruluk Performansı Analiz Çizelgesi

Sınıflandırıcı	Doğruluk
CNN	%98.5
SVM	%96.7
RF	%97.2
NN	%95.3
MLP	%96.7

CNN %98.5, RF %97.2, MLP ve SVM %96.7, NN ise %95.3 doğruluk oranı vermiştir. STFT kullanılarak yapılan çalışma sonucunda CNN yönteminin %98.5 başarı performansı ile en iyi sınıflandırma performansını gösterdiği görülmektedir. En kötü performansı ise %95.3 doğruluk oranıyla NN yönteminin sağladığı görülmektedir.

CNN, en yüksek başarıyı NJ durumlarını ayırmada göstermiş ve hiç hata yapmamıştır. En düşük başarıyı ise AM ve FM karıştırıcıları ayırmada göstermiştir.

RF, en yüksek başarıyı NJ durumlarını ayırmada göstermiş ve hiç hata yapmamıştır. En düşük başarıyı ise FM ve Chirp karıştırıcıları ayırmada göstermiştir.

SVM, en yüksek başarıyı NJ durumlarını ayırmada göstermiş ve hiç hata yapmamıştır. En

düşük başarıyı ise AM karıştırıcıları ayırmada göstermiştir.

MLP, en yüksek başarıyı NJ durumlarını ayırmada göstermiş ve hiç hata yapmamıştır. En düşük başarıyı ise AM ve Chirp karıştırıcıları ayırmada göstermiştir.

NN, en yüksek başarıyı NJ durumlarını ayırmada göstermiş ve çok az hata yapmıştır. En düşük başarıyı ise AM karıştırıcıları ayırmada göstermiştir.


Çizelge 4.4.3: STFT Veri Seti Performans Analiz Çizelgesi

	Sınıf Tipi	Kesinlik	Duyarlılık	F-Skoru
CNN	NJ	0.99	1.00	1.00
	AM	0.98	0.97	0.98
	Chirp	0.98	0.99	0.99
	FM	0.97	0.97	0.97
	NB	1.00	0.99	1.00
SVM	NJ	0.97	1.00	0.98
	AM	0.96	0.93	0.94
	Chirp	0.93	0.98	0.95
	FM	0.99	0.97	0.98
	NB	1.00	0.96	0.98
RF	NJ	0.99	1.00	1.00
	AM	0.92	0.97	0.94
	Chirp	0.97	0.96	0.96
	FM	0.99	0.94	0.96
	NB	1.00	1.00	1.00
NN	NJ	0.90	1.00	0.95
	AM	0.99	0.83	0.90
	Chirp	0.92	0.97	0.95
	FM	0.98	0.97	0.97
	NB	0.99	1.00	0.99
MLP	NJ	0.97	1.00	0.98
	AM	0.94	0.94	0.94
	Chirp	0.96	0.93	0.95
	FM	0.97	0.98	0.97
	NB	1.00	0.99	0.99

Kısa zamanlı Fourier dönüşümlerden elde edilen özneliklerin kullanılmasıyla karıştırma durumunun varlığını ayırmada %100 başarı gösterebilen bir sonuç elde edilmiştir. Ayrıca bu işlemlerde genel olarak NB karıştırıcının olduğu durumları ayırt etme performansının görece diğer durumları ayırt etmeye kıyasla daha iyi performans sergilediği ifade edilebilir. AM ve FM karıştırıcıların ayırt edilmesinde ise performans genel olarak daha düşük kalmıştır.

STFT kullanılarak yapılan çalışma sonucunda elde edilen Çizelge 4.4.3'de ve Şekil 4.4.2 sonuçları ham veri setine ait öğrenme sonuçları olan Çizelge 4.4.1 ve Şekil 4.4.1 ile kıyaslandığında direkt sinyalin kendisini kullanarak öğrenme işlemi yerine STFT aracılığıyla öznelik çıkarım işlemi ile yürütülen makine öğrenmesi sonuçlarının daha başarılı çıktılar sağladığı görülmektedir.

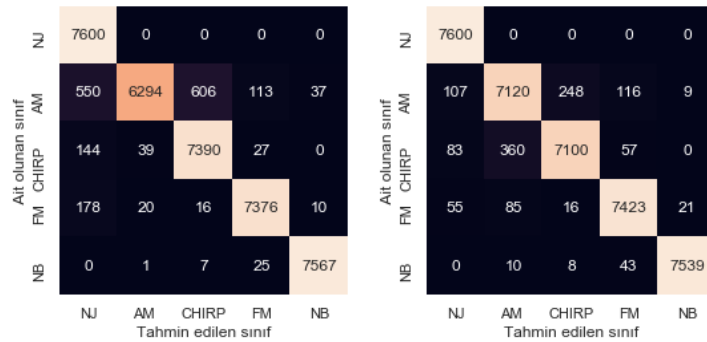
Makine öğrenmesi yöntemlerinden biri ya da birkaçında daha iyi bir sınıflandırma performansı sağlayan, karıştırma olmayan durumu tam doğrulukla ayırt edebilen bir analizin varlığını test etmek amacıyla kısa zamanlı Fourier dönüşüme ek olarak Yumuşatılmış Wigner-Ville dağılım ile elde edilen özneliklerin makine öğrenmesi algoritmalarına verilmesiyle de öğrenme performansının analiz edilmesi amaçlanmıştır.



(a) CNN

(b) SVM

(c) RF



(d) NN

(e) MLP

Şekil 4.4.2: STFT Veri Seti Karmaşıklık Matrisleri

4.4.3. Wigner-Ville Uygulanarak Çıkarılan Öznitelikleri Sınıflandırması Performansı

Yumuşatılmış Wigner-Ville uygulanarak öznitelik çıkarım işlemi gerçekleştirildiğinde her bir sinyal için 1058x2116'lık bir vektör elde edilmektedir. Bu büyüklükteki bir öznitelik matrisi ile sınıflandırma işlemi gerçekleştirmek için gereken eğitim verilerinin eğitilmesi işlemi donanım yetersizliği nedeniyle sağlanamamıştır. Veri setinin küçültülmesi için findpeaks metodu tercih edilerek özniteliklerden maksimum noktalar seçilmiş ve 60x2 boyutunda öznitelik matrisleri elde edilmiştir. Bu verilerle yürütülen öğrenme çıktılarında ise öğrenme performansının çok düşük olduğu görülmüştür. Maksimum değerlerin seçildiği 60x2'lik matrislerin büyüklükleri 200x2 büyüklüklerle değiştirildiğinde de performansın iyileşmediği görülmüştür. Bu nedenle 1058x2116 büyüklüğündeki matrisin sütunlarının toplamından 1x2116'lık bir matris elde edilmiştir. Ayrıca yine 1058x2116 büyüklüğündeki matrisin içerisindeki maksimum değerleri içeren 1x2116 büyüklüğünde bir matris daha elde edilmiştir. Böylece 2x2116 öznitelik matrisi elde edilmiştir. Böylece Yumuşatılmış Wigner-Ville dağılımı çıktısı olarak elde edilen 1058x2116 büyüklüğündeki öznitelik matrisi 2x2116 büyüklüğe sahip bir hale getirilmiştir. Bu durumda hem performans olarak daha iyi bir performans sergileyecek detayda verinin sağlanabildiği hem de işlem yapılabilecek küçüklükte bir verinin elde edilebildiği görülmüştür. Bu yaklaşıma literatürde Wigner-Ville üzerinde yapılan frekans-zaman analizi uygulamaları incelenerek ulaşılmıştır.

Wigner-Ville dağılımdan çapraz terimlerden kurtulmak amacıyla Yumuşatılmış Wigner-Ville dağılıma kullanılması ve Yumuşatılmış Wigner-Ville dağılımı sonucunda elde edilen 1058x2116 büyüklüğündeki öznitelik matrislerinin işlem yükünü azaltmak amacıyla 2x2116 büyüklüklere indirgenmesi sürecinde Wigner-Ville dağılımının sağladığı yüksek çözünürlükten ciddi anlamda feragat edilmek durumunda kalırsa da mevcut donanım kısıtları içerisinde en optimum performansın elde edilebildiği yöntemin bu olabildiği çıkarımına varılmıştır.

CNN %91.8, MLP %91.6, NN %90.5, RF %72.3 ve SVM ise %65.7 doğruluk oranı vermiştir. Yumuşatılmış Wigner-Ville kullanılarak yapılan çalışma sonucunda CNN yönteminin %91.8 başarı performansı ile en iyi sınıflandırma performansını gösterdiği görülmektedir. En kötü performansı ise %65.7 doğruluk oranıyla SVM yönteminin sağladığı görülmektedir. Bununla birlikte %72.3 doğruluk oranıyla RF yönteminin de beklenenden çok düşük performans sergilediği anlaşılmıştır.

CNN, en yüksek başarıyı NB ve NJ durumlarını ayırmada göstermiş ve neredeyse hiç hata

Çizelge 4.4.4: Wigner-Ville Veri Seti Doğruluk Performansı Analiz Çizelgesi

Sınıflandırıcı	Doğruluk
CNN	%91.8
SVM	%65.7
RF	%72.3
NN	%90.5
MLP	%91.6

yapmamıştır. En düşük başarıyı ise AM karıştırıcıları ayırmada göstermiştir.

MLP, en yüksek başarıyı NJ ve NB durumlarını ayırmada göstermiş ve neredeyse hiç hata yapmamıştır. En düşük başarıyı ise AM ve FM karıştırıcıları ayırmada göstermiştir.

NN, en yüksek başarıyı NJ ve NB durumlarını ayırmada göstermiş ve neredeyse hiç hata yapmamıştır. En düşük başarıyı ise AM ve FM karıştırıcıları ayırmada göstermiştir.

RF, en yüksek başarıyı NB ve Chirp durumlarını ayırmada göstermiş ve çok düşük hata yapmıştır. En düşük başarıyı ise NJ durumunu ayırmada göstermiştir. Karıştırma olmayan durumu hiç ayırt edemeyerek çok kötü bir performans sergilemiştir. Karıştırıcı olmayan durumun tamamını Chirp ile karıştırmıştır.


SVM, en yüksek başarıyı Chirp durumlarını ayırmada göstermiş ve az hata yapmıştır. En düşük başarıyı ise NJ ve AM durumlarını ayırmada göstermiştir. Karıştırma olmayan durumu neredeyse hiç ayırt edemeyerek çok kötü bir performans sergilemiştir. Karıştırıcı olmayan durumun tamamını Chirp ile karıştırmıştır.

Çizelge 4.4.5: Wigner-Ville Veri Seti Performans Analiz Çizelgesi

	Sınıf Tipi	Kesinlik	Duyarlılık	F-Skoru
CNN	NJ	0.99	1.00	1.00
	AM	0.98	0.67	0.79
	Chirp	0.94	0.99	0.96
	FM	0.74	0.93	0.83
	NB	1.00	1.00	1.00
SVM	NJ	1.00	0.01	0.02
	AM	0.96	0.49	0.65
	Chirp	0.49	0.99	0.66
	FM	0.59	0.93	0.72
	NB	1.00	0.86	0.92
RF	NJ	0.00	0.00	0.00
	AM	0.99	0.68	0.81
	Chirp	0.49	0.99	0.66
	FM	0.76	0.94	0.84
	NB	0.96	1.00	0.98
NN	NJ	0.96	1.00	0.98
	AM	0.93	0.68	0.78
	Chirp	0.94	0.97	0.96
	FM	0.74	0.88	0.80
	NB	1.00	1.00	1.00
MLP	NJ	0.98	1.00	0.99
	AM	0.92	0.69	0.79
	Chirp	0.95	0.99	0.97
	FM	0.75	0.90	0.82
	NB	1.00	1.00	1.00

Yumuşatılmış Wigner-Ville dağılımıyla elde edilen özniteliklerin kullanılmasıyla karıştırma durumunun varlığını ayırmada %100 başarı CNN, NN ve MLP makine öğrenmesi yöntemleri ile elde edilmiştir. Ayrıca bu işlemlerde genel olarak NB karıştırıcının olduğu durumları ayırt etme performansının görece diğer durumları ayırt etmeye kıyasla daha iyi performans sergilediği ifade edilebilir. AM ve FM karıştırıcıların ayırt edilmesinde ise performans genel olarak daha düşük kalmıştır. Ancak SVM ve RF yöntemlerinde NJ durumlarının Chirp karıştırıcı ile karıştırılması sistemin performansında ciddi bir hataya sebep olmuştur.


Yumuşatılmış Wigner-Ville kullanılarak yapılan çalışma sonucunda elde edilen Çizelge 4.4.5’de ve Şekil 4.4.3 sonuçları kısa zamanlı Fourier dönüşüm ile elde edilen öğrenme sonuçları olan Çizelge 4.4.3’de ve Şekil 4.4.2 ile kıyaslandığında SVM ve RF makine öğrenmesi yöntemlerinin Wigner-Ville kullanılarak karıştırma sınıflandırma problemlerinde daha kullanışsız bir performans sergilediği görülmektedir. Bu iki yöntem karıştırma varlığını hemen hemen hiç doğru tahmin edememiştir. CNN, NN ve MLP makine öğrenmesi yöntemlerinde ise doğruluk performanslarının görece iyi olmasına karşın kısa zamanlı Fourier dönüşüm yöntemiyle elde edilen özniteliklerle yürütülen öğrenme süreçlerine kıyasla daha başarısız sonuçlar sağladığı anlaşılmıştır. Her iki frekans-zaman analiz metodunda da AM ve FM karıştırıcıların sınıflandırma performansına negatif etki ettiği gözlenmiştir.



(a) CNN

(b) SVM

(c) RF



(d) NN

(e) MLP

Şekil 4.4.3: Wigner-Ville Veri Seti Karmaşıklık Matrisleri

Bununla birlikte SVM ve RF yöntemlerinde ham veriyle işlem yapmak çok daha başarılı sonuçlar sağlamıştır. Buna karşın CNN yönteminde benzer performanslar sergilense de ham veriyle yürütülen işlemlerde AM karıştırıcı daha yüksek başarımla ayırt edilebilirken Yumuşatılmış Wigner-Ville ile yapılan işlemlerde Chirp karıştırıcı daha başarılı şekilde ayırt edilmiştir.

Yumuşatılmış Wigner-Ville dağılımının daha yüksek çözünürlükte öznelilik seti sağlamasına rağmen işlem yükünü yönetebilmek adına uygulanan öznelilik azaltma işlemleri performansı olumsuz etkilemiştir. Bununla birlikte öznelilik çıkarma işlemleri ekstra maliyet yaratmaktadır.

Çizelge 4.4.6: Performans Analiz Çizelgesi

	Doğruluk	Sınıf Tipi	Kesinlik	Duyarlılık	F-Skoru
STFT Veri Seti - CNN	0.985	NJ	0.99	1.00	1.00
		AM	0.98	0.97	0.98
		Chirp	0.98	0.99	0.99
		FM	0.97	0.97	0.97
		NB	1.00	0.99	1.00
STFT Veri Seti - RF	0.972	NJ	0.99	1.00	1.00
		AM	0.92	0.97	0.94
		Chirp	0.97	0.96	0.96
		FM	0.99	0.94	0.96
		NB	1.00	1.00	1.00
STFT Veri Seti - SVM	0.967	NJ	0.97	1.00	0.98
		AM	0.96	0.93	0.94
		Chirp	0.93	0.98	0.95
		FM	0.99	0.97	0.98
		NB	1.00	0.96	0.98
STFT Veri Seti - MLP	0.967	NJ	0.97	1.00	0.98
		AM	0.94	0.94	0.94
		Chirp	0.96	0.93	0.95
		FM	0.97	0.98	0.97
		NB	1.00	0.99	0.99
STFT Veri Seti - NN	0.953	NJ	0.90	1.00	0.95
		AM	0.99	0.83	0.90
		Chirp	0.92	0.97	0.95
		FM	0.98	0.97	0.97
		NB	0.99	1.00	0.99
Wigner-Ville Veri Seti - CNN	0.918	NJ	0.99	1.00	1.00
		AM	0.98	0.67	0.79
		Chirp	0.94	0.99	0.96
		FM	0.74	0.93	0.83
		NB	1.00	1.00	1.00
Wigner-Ville Veri Seti - MLP	0.916	NJ	0.98	1.00	0.99
		AM	0.92	0.69	0.79
		Chirp	0.95	0.99	0.97
		FM	0.75	0.90	0.82
		NB	1.00	1.00	1.00
Ham Veri Seti - CNN	0.915	NJ	1.00	1.00	1.00
		AM	1.00	1.00	1.00
		Chirp	0.86	0.73	0.79
		FM	0.76	0.88	0.81
		NB	1.00	1.00	1.00
Ham Veri Seti - SVM	0.912	NJ	0.99	1.00	1.00
		AM	1.00	1.00	1.00
		Chirp	0.80	0.78	0.79
		FM	0.78	0.79	0.79
		NB	1.00	1.00	1.00
Ham Veri Seti - RF	0.905	NJ	0.98	1.00	0.99
		AM	0.99	1.00	1.00
		Chirp	0.77	0.82	0.80
		FM	0.80	0.73	0.76
		NB	0.80	0.73	0.76
Wigner-Ville Veri Seti - NN	0.905	NJ	0.96	1.00	0.98
		AM	0.93	0.68	0.78
		Chirp	0.94	0.97	0.96
		FM	0.74	0.88	0.80
		NB	1.00	1.00	1.00
Wigner-Ville Veri Seti - RF	0.723	NJ	0.00	0.00	0.00
		AM	0.99	0.68	0.81
		Chirp	0.49	0.99	0.66
		FM	0.76	0.94	0.84
		NB	0.96	1.00	0.98
Wigner-Ville Veri Seti - SVM	0.657	NJ	1.00	0.01	0.02
		AM	0.96	0.49	0.65
		Chirp	0.49	0.99	0.66
		FM	0.59	0.93	0.72
		NB	1.00	0.86	0.92

4.4.4. Algoritmaların Süre Performans Analizlerinin Karşılaştırılması

Algoritmaların performansını süre açısından da değerlendirebilmek adına her algoritma bir test verisi ile test edilirken hesaplanan harcanan süreler Çizelge 4.4.7 ile verilmektedir.

Çizelge 4.4.7: Algoritma Süre Performans Analiz Çizelgesi

Veri Tipi	Algoritma	Süre (ms)
Ham	CNN	7.99
Ham	RF	15.63
Ham	MLP	8.45
Ham	NN	3.50
Ham	SVM	31.2
STFT	CNN	31.29
STFT	RF	15.61
STFT	MLP	1.56
STFT	NN	15.6
STFT	SVM	46.88
Wigner-Ville	CNN	15.63
Wigner-Ville	RF	15.63
Wigner-Ville	MLP	0.02
Wigner-Ville	NN	15.62
Wigner-Ville	SVM	1.56

Çizelge 4.4.7 incelendiğinde Ham veri seti özelinde NN algoritmasının en kısa süre algoritma olduğu fakat doğruluk performansı düşük olduğu için tercih edilmemesi gerektiği çıkarımı yapılmıştır.

Doğruluk anlamında da %91 ile en iyi performansı sergileyen CNN algoritmasının 7.99 ms ile yine tercih edilebilir olduğu görülmektedir.

STFT veri tipi özelinde en yüksek doğruluğa sahip CNN algoritması 31.29 ms ile RF, MLP, NN algoritmalarından daha uzun fakat SVM'den daha kısa sürede sonuç vermektedir. STFT algoritmasında doğruluklar arasında net fark bulunmadığından eğer çok hızlı olması isteniyor ise neredeyse %96.7 doğruluk ve 1.56 ms süre ile MLP algoritması tercih edilebilir.

Wigner-Ville algoritmasında ise CNN, RF ve NN algoritmalarının 15.63 ms ile benzer sonuçlar verdiği, MLP algoritmasının 0.02 ms ile çok düşük bir sürede çözüm sunduğu ve SVM algoritmasının da diğer veri tiplerinin tersine 1.56 ms ile hızlı bir çözüm sunduğu görülmektedir. Fakat SVM algoritmasının doğruluk oranı %65.7 ile yeterli görülmemektedir. Bu sebeple Wigner-Ville için %91.6 ile tercih edilebilir olmaktadır.

5. SONUÇLAR

Bu çalışmada 4 ayrı tipte karıştırmaya uğramış ve karıştırmaya maruz kalmamış yalnızca gürültü içeren L1 bant GPS sinyallerinin sınıflandırılmasının makine öğrenmesi yöntemiyle otomatik olarak yapılmasını amaçlayan algoritmalar geliştirilmiş, test edilmiş ve sonuçlar karşılaştırılmıştır. Öğrenme algoritmalarının tamamında denetimli öğrenme yöntemleri kullanılmıştır. Yani veriye dair gözlemler makineye eğitim seti olarak verilmiş ve sağlanması gereken çıktılar tanımlanmıştır.

Oluşturulan GPS L1 sinyallerine karıştırma ve gürültü eklenmesi aşamasında sistemin sınırlarını zorlayabilecek ve literatürde sıklıkla kullanılan değerlerin üzerinde gürültü ve karıştırma sinyal güçleriyle çalışmaya özen gösterilmiştir. Özellikle karıştırıcıların etkisinin gerçek hayata yakın şartlarda test edilmesi için karıştırıcı sinyalleri üretilirken GNSS sinyalinin en az 3-4 katı güçlerde sinyallerin üretilmesi tercih edilmiştir.

Literatürde daha önce yürütülen çalışmalarda farklı karıştırma türleri, farklı öğrenme modelleri ve zaman-frekans analiz yöntemleri kullanılarak sınıflandırılmaya çalışılmış ve belirli başarı oranları elde edilmiştir. Bir çalışmada [5] AM, Chirp ve Darbe karıştırıcılar ve karıştırıcının olmadığı NJ durumu MLP, LSTM ve RC gibi öğrenme modelleriyle doğrudan uygulanmış ve performans değerleri analiz edilmiştir. Bir çalışmada ise [6] AM, FM, Darbe, Chirp ve NB karıştırıcı sinyaller ve karıştırıcı olmayan NJ durumu, elde edilen sinyal görüntülerinin doğrudan CNN ve SVM modellerine verilmesiyle sınıflandırma performansını analiz edilmiştir. Bir başka çalışmada ise [7] yine AM, FM, Darbe, Chirp ve NB karıştırıcı sinyaller ve karıştırıcı olmayan NJ durumu spektrogram çıktılarına ek olarak histogram ve güç yoğunlukları da değerlendirilerek SVM, CNN, LR ve RF makine öğrenmesi modellerine sunulmuş ve sınıflandırma performansları analiz edilmiştir. Görüldüğü üzere literatürdeki çalışmalar farklı sinyal analiz yöntemlerinin, farklı öğrenme modellerinin kullanılmasıyla karıştırıcıların sınıflandırılmasını amaçlamaktadır. Bizim çalışmamızda AM, FM, Chirp ve NB karıştırıcı sinyaller ve karıştırıcı olmayan NJ durumu doğrudan ham verilerle, STFT analizi ile elde edilen özniteliklerle ve Yumuşatılmış Wigner-Ville analizi ile elde edilen özniteliklerle olmak üzere CNN, SVM, RF, MLP ve NN öğrenme modelleriyle test edilmesi ve sonuçların analiz edilmesi hedeflenmektedir.

Bu çalışma için 50000 adet sinyal üretilmiştir. Veri seti hazırlanırken oluşturulan sinyallerin

güç, frekans, faz gibi değerleri belirlenen aralıklarda rastgele şekilde alınarak hiçbir sinyalin birbiriyle aynı olmaması sağlanmıştır. Bu durum veri setinde istenen çeşitliliğin yakalanmasına imkan vermiştir. Veri setindeki örnek sayısı belirlenirken literatürdeki farklı çalışmalarındaki yaklaşımlar ve performans sonuçları değerlendirilerek sisteme uzun işlem yükü getirmeyen ancak ezberlemeye ya da ön yargıya da neden olmayan veri seti sayısı çeşitli denemeler neticesinde belirlenmiştir.

Ham veriyle yürütülen işlemlerde oluşturulan sinyaller öznitelik çıkarılmaksızın doğrudan makine öğrenmesi algoritmalarına girdi olarak sağlanmıştır. 1057x1 büyüklüğünde matrislerden oluşan sinyallerin boyutunun küçük olması işlem hızında gözle görülür bir avantaj yaratmıştır.

STFT dönüşümünde ise sinyal üzerinde gezdirilen pencerenin yalnızca pencere içerisine giren kısmının frekans genişliğine göre işlem yapılması frekans çözünürlüğünün tüm sinyal boyunca sağlanamamasına neden olmaktadır. Zaman düzleminde sağlanan çözünürlük, frekans düzleminde zafiyetlere neden olmaktadır. Bu durum çözünürlüğün zayıf olması olarak yorumlanmıştır. Kısa zamanlı Fourier dönüşümünde hesaplama hızının daha yüksek olduğu gözlenmiştir. STFT yöntemiyle elde edilen 128x117 büyüklüğündeki öznitelik matrisleri makine öğrenmesi modellerine girdi olarak sağlanmıştır.

Öznitelik çıkarılarak yürütülecek makine öğrenmesi işlemleri için öznitelikler STFT ve Wigner-Ville dağılım metotlarıyla çıkarılmıştır. Wigner dağılımda yapısal olarak istenmeyen bazı girişimlerin ortaya çıktığı ve girişimlerden kurtulmak amacıyla frekansın negatif eşleniğinin silinmesiyle Wigner-Ville dağılıma geçilmesi gerektiği sonucuna ulaşmıştır. Wigner-Ville dağılımının ise birden fazla bileşene sahip olması durumunda sinyale bazı çapraz terimler eklediği görülmüştür. Bu terimlerden kurtulmak için bazı geçiren filtreler kullanılarak Yumuşatılmış Wigner-Ville olarak adlandırılan yöntem tercih edilmiştir. Bu yöntem ifade edilen işlemler nedeniyle ciddi bir işlem yüküne sahiptir. Bununla birlikte Wigner-Ville yöntemiyle çalışıldığında çok büyük matrislerin elde edildiği, hem zaman hem frekans düzleminde yüksek çözünürlükte çıktılarının elde edildiği görülmüştür. Ancak yüksek çözünürlük yumuşatılmış Wigner-Ville kullanılması durumunda çapraz terimlerin filtrelenmesi sırasında bazı değerli içeriklerin de filtrelenmesi nedeniyle olumsuz etkilenmektedir. Çözünürlükteki bu yoğunluk nedeniyle işlem yükü sistem ve donanım üzerinden ciddi bir yavaşlık ve kısıt yaratmıştır. Büyük hacimli matrislerle öğrenme algoritmaları koşturulmak istendiğinde

sistem kapasitesi çok az sayıda örnekle işlem yapmaya izin verebilmiştir. Az sayıda veriyle yapılan analizlerde ise öğrenme modellerinin performansı yetersiz kalmaktadır. Bu nedenle Yumuşatılmış Wigner-Ville yöntemi bir kez daha işleme tabii tutularak MATLAB findpeaks algoritması uygulanmış ve sinyalin zirve noktalarının çıkarılarak öznitelik çıkarımı için kullanılmıştır. Bu yöntemde 60x2 ve 200x2 olacak şekilde farklı iki öznitelik setiyle çalışmalar denenmiştir. Ancak Bu şekilde elde edilen öznitelik setleri de arzulanan performansı sağlayamamıştır. Bu nedenle öznitelik seti üzerinde maksimum değerleri ve varolan tüm verileri koruyacak şekilde yapısını koruyan ancak 1058x2116 büyüklüğündeki esas öznitelik matrisinden daha düşük boyutlu olan 2x2116 boyutunda bir öznitelik matrisi elde edilmiştir. Bu öznitelik setiyle elde edilen performansın bir nebze daha iyileştiği görülmüştür. Yürütülen tüm işlemler Wigner-Ville dağılımın çözünürlüğünde bir düşüşle birlikte işlem hızında bir artış sağlamıştır. Öğrenme performansına etkisi ise daha fazla örnekle öğrenmeye imkan sağladığı için pozitif olmuştur.

Makine öğrenmesi yöntemleri olarak CNN, SVM, RF, MLP ve NN modellerinin performanslarının test edilmesi hedeflenmiştir. Performans çıktıları karışıklık matrisi üzerinden ölçülmüştür. Her etiket kutusunun renginin koyulaşması doğruluğun azaldığını, renginin açılması ise doğruluğu arttığını ifade etmektedir. Karışıklık matrisi bir karar algoritmasının farklı sınıflar arasında test veri setini ne derece iyi sınıflandırıp ne derece hata yaptığı detayını da göstermektedir.

Ham verilerle yürütülen makine öğrenmesi çalışmalarında en yüksek performans %91 üzerinde bir doğrulukla SVM ve CNN modellerinde sağlanmıştır. Bunu %90 üzeri başarı gösteren RF modeli takip etmiştir. NN ve MLP modellerinin performanslarının %76 gibi bir oranla çok düşük kaldığı gözlenmiştir. Ham veriyle yapılan sınıflandırma işlemlerinde CNN, SVM ve RF öğrenme modelleri kullanıldığında NJ, NB ve AM durumlarının çok yüksek başarıyla ayrılabilirdiği ancak FM ve Chirp durumlarının birbiriyle ciddi oranda karıştırıldığı ve ayırmada zorluk yaşandığı anlaşılmıştır. FM ve Chirp karıştırıcılarının ayırt edilememesi sistemin genel performansının %99 seviyelerinden %90 seviyelerine düşmesine neden olmuştur. Karıştırmanın varlığı/yokluğu ayrımını SVM, CNN ve RF modelleri neredeyse %100 oranla doğru tespit edebilmiştir. CNN öğrenme modeli getirdiği daha düşük işlem yükü nedeniyle SVM modelinden daha hızlı bir sonuç sağlamıştır.

STFT ile elde edilen öznitelikler neticesinde yürütülen makine öğrenmesi yöntemlerine bağlı

olarak tüm makine öğrenmesi modellerinde %95 üzeri başarı sağlanmıştır. CNN %98.5, RF %97.2, SVM ve MLP %96.7 ile NN %95.3 başarı oranı sağlamıştır. CNN modelinin en yüksek, NN modelinin ise en düşük performansa sahip olduğu görülmüştür. STFT ile uygulanan öğrenme yöntemlerinin tamamında karıştırma olmayan NJ durumu tam anlamıyla doğru şekilde ayrılabilmiştir. NB karıştırıcıların ayrılmasında da çok yüksek başarı olduğu gözlenmiştir. Performansın düşük olduğu karıştırıcıların hangisi olduğuna dair genel bir değerlendirme ise AM ve Chirp karıştırıcıların ayrılmasında en düşük performansa sahip olduğu ifade edilebilir. Ham verilerle yürütülen sınıflandırma süreçlerinde olduğu gibi CNN makine öğrenmesi modelinin tercih edilmesinin diğer modellere kıyasla daha iyi performans sergilediği görülmektedir.

Yumuşatılmış Wigner-Ville ile elde edilen öznelikler neticesinde sınıflandırma performansında CNN %91.8, MLP %91.6, NN %90.5, RF %72.3 ve SVM ise %65.7 doğruluk oranları elde edilmiştir. Yumuşatılmış Wigner-Ville kullanılarak yapılan çalışma sonucunda CNN yönteminin %91.8 başarı performansı ile en iyi sınıflandırma performansını gösterdiği görülmektedir. En kötü performansı ise %65.7 doğruluk oranıyla SVM yönteminin sağladığı görülmektedir. Bununla birlikte %72.3 doğruluk oranıyla RF yönteminin de beklenenden çok düşük performans sergilediği anlaşılmıştır. Başarılı olarak nitelendirilebilecek üç öğrenme modelinin tamamında yine karıştırma olmayan NJ durumu yüksek başarıyla tespit edilerek diğer durumlardan ayrıştırılabilmektedir. Ancak RF ve SVM modellerinde NJ durumlarının tamamı Chirp karıştırıcı durumuyla karıştırılmış ve hata oranı ciddi anlamda yükselmiştir. Başarılı olarak değerlendirilebilecek CNN, MLP ve NN olarak üç model genel olarak AM ve FM karıştırıcıları birbirinden ayırt etmekte zorlanırken başarı oranı çok düşük olan RF ve SVM modelleri Chirp ve NJ durumlarını birbiriyle ayırt etmekte güçlük çekmiştir.

Karışıklık matrisi sonuçları değerlendirildiğinde performans olarak en iyi sınıflandırmanın ham veriyle çalışılan durumlarda da STFT ve Yumuşatılmış Wigner-Ville ile öznelik elde edilmesiyle çalışılan durumlarda da en başarılı öğrenme performansı CNN modeliyle yapılan çalışmalar sonucunda elde edilmiştir. Genellikle iyi sonuç veren SVM ve RF modelleri Yumuşatılmış Wigner-Ville çalışmalarında beklenen performansı sağlayamamıştır. Öyle ki ham verilerle yürütülen sınıflandırma yaklaşımlarında dahi SVM ve RF modellerinin performans değerleri Yumuşatılmış Wigner-Ville ile öznelik çıkarılarak elde edilen performanstan çok daha yukarıda gerçekleşmiştir. Bununla birlikte Yumuşatılmış Wigner-Ville ile yapılan çalışmalarda derin öğrenme mantığına dayalı makine öğrenmesi modelleri olarak ifade edi-

lebilecek CNN, MLP ve NN modellerinin performansının görece diğer modellere kıyasla daha yüksek olduğu görülmüştür. Çalışmanın neticesinde yapılan çalışmalar değerlendirildiğinde en uygun sınıflandırma yönteminin STFT ile elde edilen özniteliklerin kullanılmasıyla yürütülen tüm öğrenme modellerinin daha yüksek başarıya sahip olduğu sonucuna ulaşılmıştır. Buna ek olarak ham sinyalle yürütülen makine öğrenmesi yöntemiyle sınıflandırma çalışmalarında RF, CNN ya da SVM modellerinin kullanılabilmesi durumunda Yumuşatılmış Wigner-Ville ile öznitelik çıkarımı işleminin performansa pozitif bir etki yaratmadığı ancak eğer NN ve MLP modelleri kullanılacaksa önemli bir artış sağlanabileceği sonucuna ulaşılmıştır.

Karıştırmanın bulunmadığı durumların tespit edilmesi amaçlanan durumlarda Ham veriyle yapılan işlemlerde CNN, RF ve SVM öğrenme modellerinde, STFT ile yapılan işlemlerde tüm makine öğrenmesi modellerinde, Yumuşatılmış Wigner-Ville ile yapılan işlemlerde CNN, MLP ve NN öğrenme modellerinde %100'e yakın başarının yakalabildiği gözlenmiştir. Ham veriyle yapılan işlemlerde NN ve MLP modellerinde ve Yumuşatılmış Wigner-Ville ile yapılan işlemlerde SVM ve RF modellerinde karıştırma olmayan NJ durumunu ayırt etme performansından ciddi anlamda kayıp yaşandığı görülmüştür. Özellikle Yumuşatılmış Wigner-Ville ile yapılan işlemlerde SVM ve RF modellerinde NJ durumu hemen hemen hiç doğru sınıflandırılmayarak Chirp karıştırıcı ile benzer sınıfta etiketlenmiştir.

AM ve FM karıştırıcıların birbiryle karışması ile NJ durumu ve Chirp karıştırıcıların birbiriyle karışması durumları performans değerlerinde yaşanan kayıpların genel gerekçeleri olarak değerlendirilmektedir.

Karıştırma sinyallerinin ve karıştırıcı olmayan durumun sınıflandırılmasının makine öğrenmesi modelleriyle yürütülebilmesi süreçlerinde performansın daha artırılabilmesi bu çalışmada tercih edilen parametreler ve yöntemlerde değişiklikler yapılabileceği değerlendirilmektedir. Bu değişikliklere katman sayısının artırılması, farklı parametrelerin denenmesi, farklı öğrenme modellerinin denenmesi, veri sayısının artırılması, farklı zaman-frekans analizleri yöntemlerinin tercih edilmesi, öznitelik sayısının sistemin müsaade ettiği alan içinde artırılması gibi uygulamalar örnek olarak verilebilir.

Genel bir yorum yapılmak istenirse ham veri setinde doğruluk ve süre beraber değerlendirildiğinde CNN, STFT ve Wigner-Ville gibi Özniteliklerin çıkarıldığı durumlarda ise süre de hesaba katıldığında MLP algoritması tercih edilebilir.

Bu tez kapsamında yrtlen alıřmalarla literatre yeni bir karıřtırıcı sınıflandırma yaklařımı sunulmuřtur. Yaklařım sonucunda elde edilen veriler detaylı řekilde verilmiřtir.

KAYNAKLAR

- [1] T. Pratt and J. E. Allnutt. Satellite Communications. Wiley, Hoboken, N J, third edition edition, **2020**.
- [2] B. Hofmann-Wellenhof, H. Lichtenegger, and E. Wasle. GNSS–Global Navigation Satellite Systems: GPS, GLONASS, Galileo, and more. Springer, Wien and New York, **2008**.
- [3] Richard P. Modern Communications Jamming Principles And Techniques. The Artech House information warfare library. Artech House, Boston, MA, 2nd ed. edition, **2003**.
- [4] C. M. Bishop. Pattern Recognition And Machine Learning. Information science and statistics. Springer, New York, **2006**.
- [5] C. Wang, L.-W. Kong, J. Jiang, and Y.-C. Lai. Machine Learning-Based Approach To GPS Antijamming. GPS Solutions, 25, **2021**.
- [6] R. Morales Ferre, A. de La Fuente, and E. S. Lohan. Jammer Classification in GNSS Bands Via Machine Learning Algorithms. Sensors, 19(22):4841, **2019**.
- [7] C. J. Swinney and J. C. Woods. GNSS Jamming Classification via CNN, Transfer Learning & the Novel Concatenation of Signal Representations. In 2021 International Conference on Cyber Situational Awareness, Data Analytics and Assessment (CyberSA), pages 1–9. IEEE, **6/14/2021 - 6/18/2021**.
- [8] J. H. Wang. Antennas for Global Navigation Satellite System (GNSS). Proceedings of the IEEE, 2nd ed. edition, **2012**.
- [9] B. Hofmann-Wellenhof, Herbert Lichtenegger, and J. Collins. Global Positioning System. **2001**.
- [10] A. El-Rabbany. Introduction to GPS: The Global Positioning System. Artech House mobile communications series. Artech House, Boston, Mass. and London, **2002**. ISBN 1-58053-183-0.

- [11] J. J. SPILKER. GPS Signal Structure and Performance Characteristics. *Navigation*, 25(2):121–146, **1978**.
- [12] Sadeghi M. and Gholami M. Time Synchronizing Signal By GPS Satellites. **2008**.
- [13] Sadeghi M. and Gholami M. Time Synchronizing Signal by GPS Satellites. Dept. of Electrical Engineering University of Azad Eslamshahr branch, **2008**.
- [14] H. Habrich. Geodetic applications of the Global Navigation Satellite System (GLO-NASS) and of GLONASS/GPS combinations, volume Bd. 15 of *Mitteilungen des Bundesamtes für Kartographie und Geodäsie*. Bundesamt für Kartographie und Geodäsie, Frankfurt am Main, **2000**.
- [15] G. M. Polischuk, V. I. Kozlov, V. V. Ilitchov, A. G. Kozlov, V. A. Bartenev, V. E. Kos-senko, N. A. Anphimov, S. G. Revnivykh, S. B. Pisarev, A. E. Tyulyakov, B. V. Shebs-haevitch, A. B. Basevitch, and Y. L. Vorokhovsky. The Global Navigation Satellite System Glonass: Development and Usage in the 21st Century. pages 151–160, **2002**.
- [16] X. Li, X. Zhang, X. Ren, M. Fritsche, J. Wickert, and H. Schuh. Precise Positioning With Current Multi-Constellation Global Navigation Satellite Systems: GPS, GLO-NASS, Galileo and BeiDou. *Scientific Reports*, 5(1), **2015**.
- [17] P.J.G. Teunissen and O. Montenbruck. *Springer Handbook of Global Navigation Sa-tellite Systems*. **2017**.
- [18] M. Li, L. Qu, Q. Zhao, J. Guo, X. Su, and X. Li. Precise Point Positioning with the BeiDou Navigation Satellite System. *Sensors*, 14(1):927–943, **2014**.
- [19] A. D. Lance, K. E. Per, and X. G. Grace. *Global Navigation Satellite Systems: Report of a Joint Workshop of the National Academy of Engineering and the Chinese Academy of Engineering National Academies of Sciences, Engineering, and Medicine*. National Academies Press, Washington, D.C., **2012**.
- [20] O. Montenbruck, A. Hauschild, P. Steigenberger, U. Hugentobler, P. Teunissen, and S. Nakamura. Initial Assessment Of The COMPASS/BeiDou-2 Regional Navigation Satellite System. *GPS Solutions*, 17(2):211–222, **2013**.
- [21] V. P. Tuzlukov. *Signal Processing Noise*. The electrical engineering and applied signal processing series. CRC Press, Boca Raton, **2002**.

- [22] S. Kaur. Noise Types and Various Removal Techniques. International Journal of Advanced Research in Electronics and Communication Engineering (IJARECE), **2015**.
- [23] Anonim. Signal and Image Noise Models, (**Erişim Tarihi: 26 Nisan 2022**).
- [24] J. G. Proakis and D. G. Manolakis. Digital Signal Processing: Principles, algorithms, and applications. Prentice Hall and London : Prentice-Hall International, Englewood Cliffs, NJ., 3rd ed. edition, **1996**.
- [25] MatWorks. Manual calculation of fourier and inverse fourier transform, (**Erişim Tarihi: 27 Nisan 2022**).
- [26] Ertugrul. Ayırık Fourier Dönüşümü (DFT) & Hızlı Fourier Dönüşümü (FFT). (**Erişim Tarihi: 24 Nisan 2022**).
- [27] Quora. Are all continuous-time signals analog signals?, (**Erişim Tarihi: 27 Nisan 2022**).
- [28] J. J. Benedetto and K. Gröchenig. Foundations of Time-Frequency Analysis. **2001**.
- [29] B. Boashash. Time-Frequency Signal Analysis And Processing. Academic Press, Amsterdam, second edition edition, **2015**.
- [30] ResearchGate. Illustration of short-time Fourier transform on the test signal $x(t)$, (**Erişim Tarihi: 27 Nisan 2022**).
- [31] Y. Li and X. Meng. Convolution theorem and Wigner-Ville distribution. Proceedings of APSIPA Annual Summit and Conference, **2017**.
- [32] J. B. Manresa. THE Wigner -Ville Distribution. (**Erişim Tarihi: 24 Nisan 2022**).
- [33] S. Pikula and P. Beneš. A New Method for Interference Reduction in the Smoothed Pseudo Wigner-Ville Distribution. International Journal on Smart Sensing and Intelligent Systems, 7(5):1–5, **2014**.
- [34] M. Belgiu and L. Drăguț. Random Forest In Remote Sensing: A Review Of Applications And Future Directions. ISPRS Journal of Photogrammetry and Remote Sensing, 114:24–31, **2016**.
- [35] J. Singh. Random Forest: Pros and Cons. Random forest is a supervised learning, (**Erişim Tarihi: 26 Nisan 2022**).

- [36] Derek A. Pisner and David M. Schnyer. Support Vector Machine. In A. Mechelli and S. Vieira, editors, Machine Learning, pages 101–121. Academic Press, Amsterdam, **2019**.
- [37] Anonim. Destek Vektör Makineleri (Support Vector Machine), (**Erişim Tarihi: 26 Nisan 2022**).
- [38] W. S. Noble. What is a support vector machine?, volume 24. **2006**.
- [39] S. Alay. AlgoRithm:Destek Vektör Makineleri(Support Vector Machines)(R Kod Örnekli). Data Science for The Earth, **Anonim (Erişim Tarihi: 27 Nisan 2022)**.
- [40] A. Azaria. Deep Learning And Natural Language Processing: Multilayer_Perceptron, (**Erişim Tarihi: 24 Nisan 2022**).
- [41] J. B. Ahire. Demystifying the XOR problem. DEV Community, (**Erişim Tarihi: 26 Nisan 2022**).
- [42] L. Noriega. Multilayer Perceptron Tutorial. **2005**.
- [43] S.-C. Wang. Interdisciplinary Computing in Java Programming: Artificial Neural Network, volume 743. The Springer International Series in Engineering and Computer Science, **2003**.
- [44] ResearchGate. Facial emotion recognition using convolutional neural networks (FERC), **Anonim (Erişim Tarihi: 26 Nisan 2022)**.
- [45] S. Albawi, T. A. Mohammed, and S. Al-Zawi. Understanding Of A Convolutional Neural Network. pages 1–6, **2017**.
- [46] Z. Wu, Y. Zhao, Z. Yin, and H. Luo. Jamming Signals Classification Using Convolutional Neural Network. IEEE International Symposium on Signal Processing and Information Technology (ISSPIT), pages 062–067, **2017**.
- [47] Wikimedia Commons, (**Erişim Tarihi: 27 Nisan 2022**).
- [48] K. L. Priddy and P. E. Keller. Artificial Neural Networks: An introduction. SPIE Press, Bellingham, Wash., **2005**.
- [49] MatWorks. Feature Extraction, (**Erişim Tarihi: 26 Nisan 2022**).

- [50] Google Developers. Normalization: Data Preparation and Feature Engineering for Machine Learning, **(Erişim Tarihi: 26 Nisan 2022)**.
- [51] P. P. Ippolito. Hyperparameters Optimization., **(Erişim Tarihi: 26 Nisan 2022)**.
- [52] S. Visa, A. Inoue, and A. Ralescu. Proceedings of the Twentysecond Midwest Artificial Intelligence and Cognitive Science Conference. University of Cincinnati, **2011**.
- [53] B. Bilen. Karışıklık Matrisi (Confusion Matrix), **(Erişim Tarihi: 27 Nisan 2022)**.
- [54] C.I Goutte and E. Gaussier. A Probabilistic Interpretation of Precision, Recall and -Score, with Implication for Evaluation. pages 345–359, **2015**.
- [55] Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, Andreas Müller, Joel Nothman, Gilles Louppe, Peter Prettenhofer, Ron Weiss, Vincent Dubourg, Jake Vanderplas, Alexandre Passos, David Cournapeau, Matthieu Brucher, Matthieu Perrot, and Édouard Duchesnay. Scikit-learn: Machine Learning in Python. **2012**.
- [56] Chih-Chung Chang and Chih-Jen Lin. LIBSVM. ACM Transactions on Intelligent Systems and Technology, 2(3):1–27, **2011**. ISSN 2157-6904.
- [57] GitHub. GitHub - keras-team/keras: Deep Learning For Humans, **(Erişim Tarihi: 23 Mayıs 2022)**.
- [58] TensorFlow Developers. TensorFlow. **2022**.