T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

FARKLI HAVA KOŞULLARININ RADAR MESAFE ÖLÇÜMLERİNE ETKİSİNİN MAKİNE ÖĞRENME YÖNTEMLERİ İLE KESTİRİLMESİ

Tarık ÜNLER

DOKTORA TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Temmuz 2022
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Tarık ÜNLER tarafından hazırlanan "Farklı Hava Koşullarının Radar Mesafe Ölçümlerine Etkisinin Makine Öğrenme Yöntemleri ile Kestirilmesi" adlı tez çalışması 04/07/2022 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri **İmza**

Başkan

Prof.Dr. Ercan YALDIZ

Danışman

Doç. Dr. Levent SEYFİ

Üye

Doç.Dr. Enes YİĞİT

Üye

Dr.Öğr.Üyesi İbrahim ŞEFLEK

Üye

Dr.Öğr.Üyesi M.Fahri ÜNLERŞEN

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
LEE Müdürü

Bu tez çalışması BAP tarafından 201102047 nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Tarık ÜNLER

Tarih:

ÖZET

DOKTORA TEZİ

FARKLI HAVA KOŞULLARININ RADAR MESAFE ÖLÇÜMLERİNE ETKİSİNİN MAKİNE ÖĞRENME YÖNTEMLERİ İLE KESTİRİLMESİ

Tarık ÜNLER

Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Levent SEYFİ

2022, 61 Sayfa

Jüri
Prof.Dr. Ercan YALDIZ
Doç. Dr. Levent SEYFİ
Doç.Dr. Enes YİĞİT
Dr.Öğr.Üyesi İbrahim ŞEFLEK
Dr.Öğr.Üyesi M.Fahri ÜNLERŞEN

Bu tezde, farklı hava koşullarının radar mesafe ölçümlerine olan etkisi deneysel olarak incelenmiştir. Radar sistemleri ile tespit edilen hedeflerin konumlarını belirlemek adına yapılan mesafe ölçümleri için elektromanyetik (EM) dalganın ortamdaki hızı ışık hızı olarak kabul edilmektedir. Fakat farklı hava koşullarında bu hız değişmekte olup hassas radar uygulamaları için bu değişim büyük önem arz etmektedir. Özellikle hava savunma radarları otonom sürüş gibi yüksek hassasiyet gerektiren uygulamalar için bu durum çok büyük önem arz etmektedir. Yapılan çalışmada farklı hava koşullarında ortam parametrelerinin değişiminden dolayı EM dalganın hızında oluşacak değişimlerin incelenmesi için sabit bir mesafede bulunan hedef radar sistemi ile sürekli takip edilmiştir. Çalışmada gerçek bir radar kullanılarak çok farklı hava koşullarında ölçümler gerçekleştirilmiş ve geniş aralıklı veri seti oluşturulmuştur. Deney düzeneği bir radar ve sabit bir noktada bulunan bir yansıtıcıdan oluşmaktadır. Radardan okunan mesafe ölçümlerindeki değişimler ile hava koşulları arasındaki ilişki incelenmiştir.

Deneysel verilerin elde edilmesi için radar sistemi bir binanın çatısına yerleştirilerek ölçümler gerçekleştirilmiştir. Çalışmada radar ile mesafe ölçümü yapılırken aynı zamanda o an için sıcaklık, hissedilen sıcaklık, nem ve basınç değerleri de kaydedilmiştir. Hava durumu verileri Accuweather isimli bir uygulama üzerinden XML olarak alınmıştır. Tüm bu verilerin düzenli bir şekilde kaydedilebilmesi için C# programı ile bir arayüz programı geliştirilmiştir. Arayüz programı otomatik olarak belirli periyotlarla radardan mesafe verisini RS232 portu üzerinden almaktadır. Aynı zamanda Accuweather uygulaması üzerinden sıcaklık, hissedilen sıcaklık, nem ve basınç verileri alınmıştır. Alınan bu veriler uygulama ile yazılımın çalıştığı bilgisayar üzerinde kurulan bir SQL Server üzerine kaydedilmiştir. Kayıt işlemi yapılırken kayıt yapılan tarih ve saat kayıt altına alınmıştır. Farklı hava durumları ve farklı radar mesafe ölçümleri için 11223 adet veri kayıt altına alınarak büyük bir veri seti oluşturulmuştur. Daha sonraki süreçte kullanılan radar mesafe verisi, sıcaklık, hissedilen sıcaklık, nem ve basınç verileri kullanılarak radar mesafe hatasını tahmin edebilen bir model oluşturulmaya çalışılmıştır. Ölçüm yapılan mesafe daha önceden bilindiğinden dolayı modelde kullanılmak üzere ölçüm verisinden bilinen mesafe verisi çıkartılarak hata verisi elde edilmiştir. Böylece modelde sıcaklık, hissedilen sıcaklık, nem ve basınç verileri girdi; radar mesafe hata verisi çıktı olarak oluşturulmuştur. Hata tayini yapabilmek için MLR, SVM, ANN, KNN ve ANFIS gibi farklı yöntemler kullanılarak hatanın tahmin edilmesi sağlanmıştır. Sonuçlar analiz edildiğinde bu yöntemler arasından ANN ile hatanın çok büyük başarı ile tahmin edildiği gözlemlenmiştir. Mesafe ölçümlerinde oluşan hatanın ANN yaklaşımı kullanılarak % 7.16 hata ile tahmin edilebildiği gözlenmiştir. Böylece hassas radar uygulamalarında farklı hava şartlarından kaynaklanan radar mesafe ölçüm hatalarının telafi edilebilmesi için başarılı bir model ortaya konmuştur.

Anahtar Kelimeler: Radar ölçümleri, EM dalga hızı, Ölçüm hataları, hata tahmini, MLR, SVM, ANN, KNN, ANFIS.

ABSTRACT

PhD THESIS

ESTIMATING THE EFFECT OF DIFFERENT WEATHER CONDITIONS ON RADAR DISTANCE MEASUREMENTS BY MACHINE LEARNING METHODS

Tarık ÜNLER

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF KONYA TECHNIC UNIVERSITY
THE DEGREE OF DOCTOR OF PHILOSOPHY
IN ELECTRICAL AND ELECTRONICS ENGINEERING

Advisor: Assoc. Prof. Dr. Levent SEYFİ

2022, 61 Pages

Jury
Prof.Dr. Ercan YALDIZ
Assoc. Prof. Dr. Levent SEYFİ
Assoc. Prof. Dr. Enes YİĞİT
Asst. Prof. Dr. İbrahim ŞEFLEK
Asst. Prof. Dr. M.Fahri ÜNLERŞEN

In this thesis, the effect of different weather conditions on radar distance measurements was investigated experimentally. Today, the speed of the electromagnetic (EM) wave in the medium is accepted as the speed of light for distance measurements made to determine the positions of targets detected by radar. However, this speed changes in different weather conditions and this change is of great importance for sensitive radar applications. This situation is of great importance especially for applications that require high precision such as air defense radars and autonomous driving. In the study, in order to examine the changes in the speed of the EM wave due to the changes in medium parameters of the environment in different weather conditions, the target at a fixed distance was constantly followed by the radar system. In the study, a wide range of data set was created using a real radar in very different weather conditions. The experimental setup consists of a radar and a reflector at a fixed point. The relationship between the changes in the distance measurements read from the radar and the weather conditions was examined.

Measurements were made by placing the radar system on the roof of a building. In the study, while measuring the distance with the radar, the temperature, sensed temperature, humidity, and pressure values for the moment were also recorded. Weather data was taken as XML from an application called Accuweather. A GUI has been developed with the C# software so that all these data can be recorded regularly. It automatically receives the distance data from the radar at certain intervals via the RS232 port. At the same time, temperature, sensed temperature, humidity, and pressure data were obtained through the Accuweather application. These received data were recorded on a SQL Server installed on the computer where the application and the software were running. During the registration process, the date and time of the registration were recorded. A large data set was created by recording 11223 data for different weather conditions and different radar distance measurements. A model that can predict the radar distance error was tried to be created by using the radar distance data, temperature, sensed temperature, humidity, and pressure data used in the next process. Since the measured distance was known beforehand, the error data was obtained by subtracting the known distance data from the measurement data to be used in the model. Thus, temperature, sensed temperature, humidity and pressure data was created as input; radar distance error data as output in the model. Then, the error was estimated by using different methods such as MLR, SVM, ANN, KNN and ANFIS. When the results were analyzed, it has been observed that the error was predicted with great success with ANN, one of these

methods. It has been observed that the error in distance measurements can be estimated with an error of 7.16% using the ANN approach. Thus, a successful model has been presented to compensate for radar distance measurement errors caused by different weather conditions in sensitive radar applications.

Keywords: Radar measurement, EM wave velocity, Measurement error, Error estimation, MLR, SVM, ANN, KNN, ANFIS

ÖNSÖZ

Öncelikle tez çalışmamın her aşamasında bana destek olan ve değerli bilgi birikimiyle bana yol gösteren danışman hocam Doç. Dr. Levent SEYFİ'ye teşekkürlerimi sunarım.

Doktora tezim boyunca benden değerli fikirlerini esirgemeyen ve tez çalışmama sağladıkları katkılar dolayısıyla tez izleme komitesindeki Prof.Dr. Ercan YALDIZ ve Doç.Dr. Enes YİĞİT'e teşekkürü bir borç bilirim.

Son olarak, rahmetli babama, eğitim hayatımın her aşamasında benden maddi ve manevi desteklerini esirgemeyen anneme ve çalışmalarım boyunca bana destek olan eşime teşekkürü bir borç bilirim.

Tarık ÜNLER
KONYA-2022

İÇİNDEKİLER

ÖZET i

ABSTRACT iii

ÖNSÖZ v

İÇİNDEKİLER vi

SİMGELER VE KISALTMALAR viii

1. GİRİŞ 1

2. KAYNAK ARAŞTIRMASI 3

3. MATERYAL VE YÖNTEM 11

3.1. Radarlar ve Elektromanyetik Teori 11
3.1.1. Farklı ortamlarda elektromanyetik özellikler 12
3.1.1.1. Kayıpsız ortamlarda EM dalganın hızı 14
3.1.1.2. İyi iletken ortamlarda EM dalganın hızı 14
3.1.1.3. Az kayıplı ortamlarda EM dalganın hızı 15
3.2. Kötü Hava Koşullarında Radar Mesafe Hatalarının Tespit Edilmesi 16
3.2.1. Deney düzeneği 17
3.3. Deneysel Düzeneğin Çalışması 24
3.4. Verilerin Toplanması ve Analizi 26
3.4.1. Çoklu doğrusal regresyon (Multiple Linear Regression, MLR) 26
3.4.2. Destek vektör makineleri-regresyon (Support Vector Machine – Regression SVM-R) 27
3.4.3. Bulanık çıkarım sistemi (Adaptive Neuro Fuzzy Inference System, ANFIS) 28
3.4.4. K-En yakın komşu algoritması (K-Nearest Neighbors, KNN) 29
3.4.5. Yapay sinir ağları (Artificial Neural Networks, ANN) 30
3.4.5.2 Biyolojik sinir hücresi yapısı 31
3.4.5.3. Yapay sinir ağını oluşturan birimler 34
3.4.5.4. Yapay Sinir Ağlarının Sınıflandırılması 36
3.4.5.4.1. Yapısal sınıflandırma 37
3.4.5.4.1.1. İleri beslemeli ağ 37
3.4.5.4.1.2. Geri beslemeli ağ 37
3.4.5.4.2. Öğrenme yöntemlerine göre sınıflandırma 38
3.4.5.4.2.1. Danışmanlı öğrenme yöntemi 38
3.4.5.4.2.2. Danışmansız öğrenme yöntemi 39

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA 40

4.1. Değerlendirme Kriterleri 40
4.1.1. Ortalama mutlak hata (Mean Absolute Error, MAE) 40
4.1.2. Ortalama mutlak yüzde hata (Mean Absolute Percentage Error, MAPE) 41
4.1.3. Ortalama kare hata (Mean Squared Error, MSE) 41

4.1.4. Kök ortalama kare hata (Root mean square error, RMSE) **42**
4.2. Verilerin Analizi ve Dağılımı **42**
4.2.1. SVM-R yönteminin sonuçları **45**
4.2.2. MLR yönteminin sonuçları **46**
4.2.3. ANFIS yönteminin sonuçları **47**
4.2.4. KNN yönteminin sonuçları **48**
4.2.5. ANN yönteminin sonuçları **49**
4.3. MLR, SVM, ANFIS, KNN ve ANN Yöntemlerinin Karşılaştırılması **50**

5. SONUÇLAR VE ÖNERİLER **55**

5.1 Sonuçlar **55**
5.2 Öneriler **56**

KAYNAKLAR **57**

EKLER **61**

ÖZGEÇMİŞ .....Hata! Yer işareti tanımlanmamış.

SİMGELER VE KISALTMALAR

Simgeler

ε : Ortamın dielektrik geçirgenliği (F/m)

ε_0 : Boşluğun elektrik geçirgenliği (F/m)

ε_r : Dielektrik sabiti

μ : Ortamın manyetik geçirgenliği (H/m)

μ_0 : Boşluğun manyetik geçirgenliği (H/m)

μ_r : Bağıl manyetik geçirgenliği

ω : Açısal frekans (rad/s)

σ : İletkenlik (S/m)

u : EM dalganın faz hızı(m/s)

Kısaltmalar

EM : Elektromanyetik

ANN : Yapay sinir ağları

SVM-R: Destek vektör makinası regresyon

KNN : K-en yakın komşuluk

FL : Bulanık mantık

ANFIS : Uyarlamalı sinirsel bulanık çıkarım sistemi

MLR : Çoklu lineer regresyon

RMSE : Kök Ortalama Kare Hata

MAE : Ortalama mutlak hata

MSE : Ortalama kare hata

MAPE : Kök ortalama kare hata

TTM : Hedef takip modu

XML : Genişletilebilir işaretleme dili

SQL : Yapılandırılmış sorgu dili

DC : Doğru akım

NMEA : Ulusal deniz elektroniği derneği

SAR : Sentetik açıklıklı radar

SMPS : Anahtarlamalı güç kaynağı

1. GİRİŞ

Radar hesaplamaları yapılırken elektromanyetik dalgaların (EM) yayılma hızları çok büyük önem arz etmektedir. EM dalganın yayılma hızı yaklaşık olarak $3x10^8$m/s olarak alınmaktadır. Ancak bu hız EM dalganın boşluktaki hızıdır ve normal hava koşullarında eşdeğer hızda yayıldığı kabul edilir (Tuncer, 2011). Bu değer olumsuz hava koşullarında değişkenlik göstermektedir. Örneğin kar taneleri erirken üzerindeki su oranının artışıyla şekilleri, boyutları ve yoğunluklarında değişim görülür. Bu değişimlerin radarlarda ve uydu haberleşmelerinde kullanılan mikrodalgaların yayılım hızı üzerinde etkisi söz konusudur. Radar sinyallerinin yansımasının radar ile yapılan meteorolojik ölçümlerde önemli sonuçları vardır çünkü radar çıkarımlı yağış tahminlerinde hatalara sebep olur (Conyers ve Goodman, 1997).

Kar taneleri, buzun hava, su veya her ikisi ile oluşan bir karışımıdır. Karışım oranı ve bileşenlerin şekilleri, kar parçacıklarının maruz kaldığı dış meteorolojik koşullara bağlı olarak önemli ölçüde değişebilir. Böyle bir karışımın elektriksel özelliklerinin teorik hesaplamasında, bileşen malzemelerin oranı (kar-su) dielektrik sabitini belirlemektedir. Bununla birlikte, böyle bir karışımın etkin dielektrik sabitinin bulunması oldukça zor bir sorundur. Çünkü bileşen malzemeler arasında etkileşimler meydana gelebildiği bilinmektedir (Oguchi, 1983).

Bu tez çalışmasında farklı hava koşullarının radar ölçümlerine olan etkileri araştırılmıştır. Radar ile tespit edilen hedefin konumunun hesabında kullanılan EM dalga hız değeri ortamın dielektrik sabiti ve öz iletkenliğine bağlı olarak değişmektedir. Farklı hava koşullarının dielektrik sabitleri ve öz iletkenlikleri farklı olacağı için EM dalganın hız değeri de değişecektir. Günümüzde radar hesaplamalarında hassasiyet hem askeri hem de sivil uygulamalar için büyük önem arz etmektedir. Örneğin, savunma sistemlerinde hedefin doğru konumda hassas bir şekilde belirlenebilmesi çok önemlidir (Üstüner, 2006). Özellikle hassas güdümlü füze atışları için yapılacak en küçük hata ciddi sonuçlar doğurabilir.

Literatürde farklı hava koşullarında EM dalganın hız değişimi ile ilgili deneysel herhangi bir çalışma bulunmamaktadır. Dolayısı ile bu çalışmanın ortaya çıkaracağı sonuçların özellikle hassas uygulamalar için kötü hava koşullarında dahi hedef konumunun yüksek doğrulukta tespitine katkı sağlayacağı düşünülmektedir.

Bu tez çalışmasında özellikle olumsuz hava koşullarında değişken olan EM dalganın hızının değişiminin etkisi deneysel olarak belirlenerek radar konum

hesaplarında oluşan hatalarının azaltılması için çalışmalar gerçekleştirilmiştir. Çalışmada sabit konumda bulunan bir yansıtıcının radar ile sürekli mesafe ölçümleri yapılmıştır. Aynı zamanda ölçüm yapılan anlar için hava durum verileri okunmuştur. Verilerin tamamı bir veri tabanı üzerinde C# ile oluşturulan bir yazılım sayesinde kayıt altına alınmıştır. Radardan alınan veriler RS232 portu üzerinden tasarlanan uygulama sayesinde okunarak veri tabanı üzerine kaydedilmiştir. Hava durumu verileri ise Accuweather üzerinden XML ile yapılan ara yüz ile radar verisi ile veri tabanı üzerine kaydedilmiştir. Uygulama üzerinden sıcaklık, hissedilen sıcaklık, nem ve basınç verileri kayıt altına alınmıştır. Çalışmada farklı günlerde alınan ve çok farklı hava koşullarını kapsayan toplamda 11223 adet veri kullanılmıştır. Önceden mesafesi bilinen hedef yansıtıcının radar ile ölçülen mesafe değeri ile gerçek mesafe değerinin farkı alınarak hata verisi elde edilmiştir. Veri tabanına kaydedilen hava durumu verileri girdi, radar ölçümünden elde edilen hata verisi çıktı olacak şekilde MLR, SVM, ANN, KNN ve ANFIS yöntemleri ile bu hatanın tahmini gerçekleştirilmiştir. Böylece kötü hava koşullarından kaynaklanan hataların büyük bir doğrulukla tahmin edilerek çok daha doğru bir mesafe ölçümü için altyapı oluşturulmuştur.
Bu sayede özellikle savunma sanayi, otonom sürüş gibi çok hassas mesafe ölçümlerine ihtiyaç duyan uygulamaların yapıldığı alanlarda her koşulda çok daha hassas konum ölçümlerinin yapılmasına katkıda bulunulacağı düşünülmektedir.

Gerçekleştirilen bu tez çalışması toplamda beş bölümden oluşmaktadır. Tezin birinci bölümü giriş kısmı olup ikinci bölümde kaynak araştırması adı altında literatürde yapılan benzer çalışmalar ele alınmıştır. Üçüncü bölümde tez çalışmasında kullanılan materyal ve yöntemden bahsedilmiş, çalışmada kullanılan deneysel düzenek hakkında bilgi verilmiştir. Dördüncü bölümde ise gerçekleştirilen çalışmalar ve elde edilen bulgular anlatılmıştır. Beşinci bölüm, çalışmanın son bölümü olup sonuçlar ve öneriler kısmından oluşmaktadır.

2. KAYNAK ARAŞTIRMASI

Tiuri ve ark. mikrodalga frekanslarında karın dielektrik sabiti ölçümünü yaptıkları çalışmada karın dielektrik sabiti üzerindeki etkisini incelemişlerdir. Bu çalışmada dielektrik sabitinin imajiner kısmının karın yapısından bağımsız olduğunu bulmuşlardır. Kuru kar için karın yoğunluğunun dielektrik sabitini belirlediğini tespit etmişlerdir. Islak kar için ise hem imajiner kısım hem de gerçek kısmın ıslaklıkla arttığını ölçmüşlerdir (Tiuri ve ark., 1984).

Tomohiro, karlı ve yağışlı havalarda Elektromanyetik dalganın yayılma ve saçılmalarını araştırmıştır. Çalışmasında 5 GHz frekansında çalışan bir vericinin olumsuz hava koşullarının verici performansı üzerindeki etkilerini incelemiştir. Çalışmada özellikle yağışlı havaların etkileri üzerinde durulmuştur. Kar parçacıklarının hava, su veya kar ve su ile oluşan bir karışım olduğu belirtilmiştir. Karışım oranının ve bileşenlerin şekillerinin, kar parçacıklarının maruz kaldığı dış meteorolojik koşullara bağlı olarak önemli ölçüde değişebildiği belirtilmiştir. Böyle bir karışımın elektriksel özelliklerinin teorik hesaplamasında, bileşen malzemelerin dielektrik sabitini belirleyecek kadar büyük olduğu varsayılmıştır. Bununla birlikte, bileşen malzemeler arasında çok sayıda etkileşim meydana geldiğinden, böyle bir karışımın etkin dielektrik sabitinin bulunmasının oldukça zor olduğu belirtilmiştir. Bu durumda dielektrik sabitinin hesaplanması için sadece çeşitli yaklaşımların kullanılabileceği ifade edilmiştir (Tomohiro, 1983).

Conyers ve Goodman, olumsuz hava koşullarında EM dalganın hızının değişkenlik gösterebileceğini ifade etmektedir. Özellikle yağış ardından kar tanelerinin erimesi esnasında üzerlerindeki su oranının yükselmesi ve boyutlarının değişimleri EM dalganın yayılma hızı üzerinde etkili olmaktadır. Bu durum örneğin radar tabanlı yağış tahminlerinde hatalara sebep olabilmektedir (Conyers ve Goodman, 1997).

Van der Kruk ve ark. yapmış oldukları yere nüfuz eden radar çalışmasında yüzeyin engebeli oluşunun ve toprak iletkenlik farklılıklarının yüzey altı yapıların tanımlanmalarını zorlaştırdığından bahsetmişlerdir. Yere nüfuz eden radarların ürettiği 10 MHz ile 6 GHz arası EM sinyallerinin yer içinde yayılımı sırasında farklı elektriksel özelliklere sahip ortamlardan geçerken enerjilerinin kısmen geri yansıdığını ve radarın alıcı anteninde dalganın geri gelme zamanının beklenenden farklı olduğunu belirtmişlerdir. Hataların önlenmesi ve yanlış nesne tespitinin önüne geçebilmek için anten koruyucuları kullanımını önermişlerdir. Ayrıca çalışmalarında farklı frekanslara

sahip antenler kullanarak aynı noktada yapılan ölçüm sonuçlarını karşılaştırmışlardır (Van der Kruk ve ark., 1998).

Solheim ve ark. yapmış oldukları çalışmada kuru havanın, yağışlı havanın ya da atmosferde bulunan volkanik kum (toz) partiküllerinin mikrodalga gecikmesine sebep olduğunu belirtmişlerdir. GPS uygulamalarında en yüksek hassasiyetin alınabilmesi için bu parametrelerin iyi karakterize edilmiş olması gerektiğini belirtmişlerdir. Çalışmada bir km'lik mesafede meydana gelen çok şiddetli bir yağmurun mikrodalga gecikmesinden kaynaklı olarak 15mm'lik bir hataya neden olduğunu tespit etmişlerdir (Solheim ve ark., 1999).

Fujita ve ark. EM dalganın buzda ilerlemesi ile ilgili yaptıkları çalışmada EM dalganın dielektrik sabitinin MHz mertebesindeki frekanslarda birçok faktörden etkilendiğini belirtmişlerdir. Bu faktörlerin yoğunluk, saflık konsantrasyonu (asitlik derecesi), sıcaklık, hidrostatik, basınç ve hava kabarcıkları olduğunu ifade etmişlerdir. Ayrıca buzun içinde EM dalganın faz hızının boşluktaki hızından farklı olarak $1.69x10^8$ m/s (ışık hızının yaklaşık %56'sı) civarında olduğunu hesaplamışlardır (Fujita ve ark., 2000)

Bruder ve ark. kötü hava koşullarının milimetre dalga boyundaki radarlara olan etkisini incelemişlerdir. Çalışmada kötü hava koşullarının radar çalışmasını olumsuz etkilediğinden bahsetmişlerdir. Radar ölçümü yapılan ortamda meteorolojik verileri temin etmek için anemometre, termometre, nem sensörleri gibi farklı ölçüm araçları kullanmışlardır. Özellikle gemi savunması ve füze gibi milimetre dalga boyunda küçük anten kullanan uygulamaların radar ölçümleri için havanın; sis, yağmur, duman, buz ve kar oranlarının önemli olduğunu ifade etmişlerdir. Hassas ölçümler için bu parametreler dikkate alınmadan yapılacak ölçümlerin hatalı olacağını belirtmişlerdir (Bruder ve ark., 2002).

Törmä ve Engdahl sentetik açıklıklı radar (SAR) görüntülerine mevsimsel hava şartlarının etkisini incelemiştir. Yapılan ölçümler sonucunda yağmurlu, karlı ve yağışsız günlerde alınmış olan SAR görüntüleri kıyaslanmıştır. Yoğunluğu yüksek olan görüntülerin bahar aylarında alındığı tespit edilmiştir (Törmä ve Engdahl, 2003).

Leckebusch, yapmış olduğu çalışmada yere nüfuz eden radar için etki eden fiziksel parametreleri araştırmıştır. Çalışmasında dielektrik sabiti, öz iletkenlik, zayıflama, yatay ve dikey çözünürlük, dalga boyu gibi konuları incelemiştir. Ayrıca yaptığı çalışmada EM dalganın zayıflamasının (α), içinde bulunduğu ortamın manyetik ve elektrik geçirgenliklerine bağlı olarak değiştiğini belirtmiştir. Derinlik arttıkça

radardan yayılan EM dalgalarının hızlı bir şekilde zayıfladığını ve bu durumun dalgaların küresel yayınımının uzaklık ile ters orantılı olmasıyla da ilişkili olduğunu ifade etmiştir (Leckebusch, 2003).

Conyers, yapmış olduğu çalışmada EM dalgaların, zamanla değişen elektrik ve manyetik alan bileşenlerinden oluştuğunu ve bu bileşenler içinden geçtikleri ortamın dielektrik sabiti, öz iletkenlik ve manyetik geçirgenlik gibi elektriksel özelliklerinden etkilendiğini belirlemiştir. Bu özelliklerin EM dalganın yayılmasına etki ettiği gibi zayıflamasına da sebep olduğu ifade edilmiştir (Conyers, 2004).

Korkmaz, yaptığı çalışmada kar taneciklerinin havadayken erimesi ile yağmur damlacığına dönüştüğü ortamın farklı frekanslar için RF sinyallerine etkisini incelemiştir. Kar tanelerinin erime yüzdelerinin ve dielektrik sabitlerinin belirlenmesi amacıyla bir erime katmanı modeli çıkarmıştır. Bu sayede katman boyunca RF sinyallerinin yansıma ve sönümlenmeleri S, X ve Ka bandlarında hesaplanmıştır. Frekans değeri artırıldığında sönümlenmenin arttığı, yansıma oranının ise azaldığı gözlemlenmiştir (Korkmaz, 2004).

Adegoke ve Onasanya yapmış oldukları çalışmada radyo sinyallerinin atmosferde yayılırken kırılma indisindeki değişimlerden etkilendiklerini ve yayılma hızlarında da azalmaya neden olacağını belirtmişlerdir. Bu yayılma gecikmesinin hatalı ölçümlere de neden olacağını anlatmışlardır. Bu gecikmeye kuru hava, su buharı, hidrometeorlar ve diğer partiküller (kum, toz, nem, volkanik kül vb.) gibi faktörlerin neden olduğunu belirtmişleridir (Adegoke ve Onasanya, 2008).

Maity ve ark. yapmış oldukları çalışmada, EM dalganın yayılma gecikmesinin meteorolojik parametreler ile olan ilişkisini incelemişlerdir. Sıcaklık değişimi, su buharı yoğunluğu ve bulutlardaki yoğunluk değişiminin yayılma gecikmesi değişiminde önemli rol oynadığını söylemişlerdir. Ayrıca atmosferde bulunan nemin yayılma gecikmesinin yanında sinyalin zayıflamasına da neden olduğunu gözlemlemişlerdir (Maiti ve ark., 2009).

Sugiyama ve ark. yaptıkları çalışmada karın dielektrik özelliklerinin bilinmesinin EM dalganın yayılıma özelliklerinin belirlenmesi için önemli bir ölçüt olduğunu belirtmişlerdir. Dielektrik sabitinin özellikle EM dalganın yayılma kabiliyetinin belirlenmesi konusunda çok önemli olduğunu ortaya koymuşlardır. Ancak bu parametrelerin belirlenmesinin zor olduğunu özellikle karın ıslak olmasına göre dielektrik sabitinin değiştiğini ifade etmişlerdir (Sugiyama ve ark., 2010).

Tuncer yapmış olduğu tez çalışmasında radar hesaplamaları yapılırken EM dalgaların yayılma hızlarının çok büyük önem arz ettiğini ifade etmektedir. EM dalganın yayılma hızı yaklaşık olarak $3x10^8$m/s olarak alınmaktadır. Ancak bu hız EM dalganın boşluktaki hızıdır ve normal hava koşullarında eşdeğer hızda yayıldığı kabul edildiğini belirtmiştir (Tuncer, 2011).

Doerry yapmış olduğu çalışmada radar ölçümlerinde EM dalganın boşluktaki hızının referans alındığını söylemiştir. Ancak atmosferde farklı hava koşullarında radar ölçümlerinde sabit bir hız alındığından dolayı ölçüm hatalarına neden olduğunu ifade etmiştir. Atmosferin dielektrik özellikleri, sıcaklık, atmosferik basınç ve özellikle nemin EM dalgada yayılma gecikmesine neden olduğunu belirtmiştir. Atmosferik etkenlerden kaynaklanan bu durumun mesafe ölçüm hatalarına neden olduğunu belirtmiştir (Doerry, 2013).

Küçükdemirci yapmış olduğu tez çalışmasında Aizanoi Antik Kenti ve Heraion Teichos Akropolü'nde sığ derinliklerdeki arkeolojik öneme sahip kalıntıların belirlenebilmesi ve bunların fiziksel ve geometrik özelliklerinin tanımlanması amacıyla manyetik ve yer radarı (GPR) yöntemlerini uygulamıştır. Her iki jeofizik yöntemle elde edilen verileri önce birbirinden bağımsız şekilde incelemiştir. Sonuç olarak yeraltında temeller, duvarlar ve yol olabileceği düşünülen düzgün geometrik özelliklere sahip yapılar gözlenmiştir. Yaptığı çalışmada öz iletkenlik ve dielektrik sabitindeki değişimlerin, manyetik geçirgenlikteki değişimlere nazaran daha önemli olduğunu ifade etmiştir (Küçükdemirci, 2014).

Özdemir, yaptığı çalışmada Karadeniz Teknik Üniversitesi Kanuni yerleşkesinde konum bilgileri bilinmeyen alt yapı unsurlarının (metalik ve metalik olmayan borular, telefon/elektrik/fiber optik kablolar) yer radarı yöntemi ile belirlenmesi için ölçümler yapmıştır. Çalışmada ölçümler, 21 inceleme alanında birbirine paralel yollar üzerinde 250, 500 ve 800 MHz frekanslarında gerçekleştirilmiştir. Elde edilen veriler işlendikten sonra 2 ve 3 boyutlu görüntüler elde edilmiştir. Bu görüntüler ile modelleme çalışmalarındaki görüntüler karşılaştırılarak, hangi bölgede hangi alt yapı elemanlarının bulunduğu ortaya çıkarılmıştır. Çalışmada ara yüzeyin miktarı ve bölgeler arasındaki elektriksel özelliklerdeki değişimin, sinyalin zayıflama miktarını ve radarının yeraltını analiz edebilme yeteneğini etkilediği anlatılmaktadır. Elektriksel özelliklerdeki değişimin ortamda ilerleyen EM dalgalarının hızına ve nüfuz derinliğine de etki ettiği belirtilmiştir (Özdemir, 2015).

Fornaro ve ark. yapmış oldukları çalışmada mikrodalganın yayılması esnasında atmosfer ortamında zayıflama yaşadığını, atmosfer ortamının aynı zamanda mikrodalga yayılması için bir hata kaynağı olduğunu belirtmişlerdir. Özellikle GPS uygulamaları için sinyal gecikmesinin hatalı ölçümlere neden olduğunu belirtmişlerdir (Fornaro ve ark., 2014).

Yayla yapmış olduğu tez çalışmasında atmosfer içinde bulunan gazlar ve hidrometeorların (yağmur, dolu, kar, bulut, sis gibi) yayılan elektromanyetik dalgaların sönümlenmesine neden olduğunu belirtmiştir. Yapılacak tasarımlarda bunların dikkate alınması gerektiğine değinmiştir. Ayrıca farklı özelliklere sahip katmanlardan oluşan atmosfer içinde kırılma indisinin (n) sabit olmadığından bahsetmiştir. Atmosfer içinde yükseklere çıkıldıkça kırılma indisi değerinin azaldığından söz etmiştir. Elektromanyetik dalgaların hızlarının yayıldıkları ortama göre değişiklik gösterip ortamın yoğunluğu ile elektromanyetik dalgaların hızının ters orantılı olduğunu söylemiştir. Yaptığı çalışmada zayıflama miktarının belirlenmesine yönelik bazı modelleri, MATLAB programı kullanarak simüle etmiş ve incelemiştir (Yayla, 2016).

Yılmaz yapmış olduğu doktora tez çalışmasında duvar arkasındaki sabit ve hareketli hedeflerin yerini tespit etmeye yönelik algoritmalar geliştirmiştir. Ayrıca, göçük altında hareketsiz duran bir hedefin yaşamsal verilerinin tespit edilmesi amacına yönelik deneyler gerçekleştirmiştir. Bu amaçla, duvar arkasında hareketsiz duran bir kişinin solunum ve kalp atışlarının tespit edilmesine yönelik deneysel çalışmalar yaparak başarılı sonuçlar elde etmiştir. Teorik hesaplama sonucunda hedefin antenden 2.73 m uzaklıkta olması gerektiğini hesaplamıştır. Ancak duvar arkasında tespit edilmeye çalışılan hedefin 2.8 m'de olduğunu ölçümlemiştir. Çalışmasında bu farkın çok küçük olduğundan dolayı ihmal etmiştir. Bu farkın duvar arkası görüntüleme operasyonları için önemsiz olduğunu belirtmiştir (Yılmaz, 2017).

Norouzian ve ark. yapmış oldukları çalışmada kar yağışının 300 GHz dalga boyundaki dalgalara olan etkilerini incelemişlerdir. Çalışmada en büyük zayıflamayı en yoğun kar yağışı anında ölçmüşlerdir. Kar yağışlarını ıslak kar ve kuru kar olarak sınıflandırmışlardır. Islak karda zayıflamanın daha çok olduğunu gözlemlemişlerdir (Norouzian ve ark., 2018).

Rahimi ve ark. yapmış oldukları çalışmada toprağın neminin çekilen fotoğraflarını kullanarak tahmin edilebilmesi için ANFIS kullanmışlardır. ANFIS'te üçten fazla girdi olduğunda daha büyük bir doğruluk olmasına rağmen çok daha karmaşık işlemlerin yapıldığını ve çözüm için daha uzun bir zamana ihtiyaç olduğunu

belirtmişlerdir. Çalışma sonucunda büyük bir doğrulukla farklı nem değerlerindeki toprak örneklerinin tahmin edildiğini belirtmişlerdir (Rahimi ve ark., 2018).

Tabanna yeraltında su tespiti için yere nüfuz eden radar çalışması yapmıştır. Çalışmada performansı arttırmak için PCA, ICA, SVD, PICA Median, Gaussian, Histogram, gibi birçok filtre algoritması üzerinde çalışmıştır. Çalışmada öncelikle kumla dolu 10 mm çapında bir küre ile ölçümler yaptıktan sonra kürenin içini su ile doldurarak ölçümleri tekrarlamıştır. Yaptığı ölçümler esnasında dielektrik sabitinin radar sinyallerin faz hızını etkilediğini belirtmiştir. Ayrıca yer radarlarında özellikle iletkenliği yüksek toprakta hedeflerin bulunmasının zorlaştığını belirtmiştir (Tabanna, 2019).

Tanimu yapmış olduğu çalışmada yollar ve köprüler gibi altyapılarda gelecekte sorunlara yol açabilecek çatlakların önceden tespit edilmesi üzerine çalışmıştır. Yaptığı çalışmada diğer yöntemlerden farklı olarak incelenecek parçaya zarar vermeden yer radarı analizlerini kullanarak materyallerdeki çatlakları analiz etmeyi amaçlamıştır. Yeraltı radarlarının hedefin konumunu tespit etmek için EM sinyallerin geliş gidiş süresini kullanarak bu sürenin radar sinyallerinin ilerlediği ortamın dielektrik sabitine bağlı olduğundan söz etmiştir. Farklı dielektrik sabitine sahip ortamlarda EM dalgaların hızlarının da farklı olacağını belirtmiştir (Tanimu, 2019).

Genç, yapmış olduğu çalışmada mevcut GPR tabanlı mayın tespit ve tanımlama yöntemlerinin yanlış alarm oranlarını azaltmak için fizik-tabanlı yöntemler ile görüntü-tabanlı yöntemleri bir arada kullanmıştır. Çalışmasında önerilen algoritma için, yarısından fazlası hiç metal içermeyen 300'den fazla simüle edilmiş mayın modeli ve 400'den fazla simüle edilmiş zararsız cisim modeli kullanarak test etmiştir. Yaptığı çalışmada yere nüfuz eden radarda toprağın farklı dielektrik ve iletkenlik değerleri için hızın değişimini hesaplamıştır. Kalibrasyon yaparak doğru sonuçlar elde etmek için hız, zayıflama gibi bilgileri göz önünde bulundurmuştur (Genç, 2019).

Zang ve ark. yaptıkları çalışmada özellikle otonom sürüş yapan araçlarda yağmur ve kar anlarında sistemlerin doğru çalışmadığını belirtmişlerdir. Ancak otonom araçların kötü hava şartlarında sensör ve radar sistemlerinin kötü hava şartlarından nasıl etkilendiğini anlatan sistematik bir çalışmanın bulunmadığından bahsetmişlerdir. Çalışma sonucunda yapmış oldukları simülasyon çalışmasında kötü hava şartlarında ölçüm mesafesinin %45 oranında azaldığını tespit etmişlerdir (Zang ve ark., 2019).

Norouzian ve ark. yapmış oldukları çalışmada farklı frekanslarda ve farklı yağmur yoğunluklarında yapmış oldukları çalışmada yağmurun EM dalganın

zayıflamasına sebep olduğunu tespit etmiştir. Yağmur yağarken troposferde ilerleyen bir EM dalga yağmur damlaları tarafından hem soğurulacak hem de dağıtılacaktır. Bu iki etki EM dalganın gücünün azalmasına ve alıcı tarafında daha zayıf bir sinyal olarak ulaşmasına neden olacağını belirtmiştir (Norouzian ve ark., 2019).

Bilgiç ve Mert yapmış oldukları çalışmada atmosferik verileri girdi olarak kullanarak radyasyonun tahmin edilebilmesi için MLR, ANFIS ve ANN yöntemlerini kullanarak model oluşturmuşlardır. Kullanılan bu yöntemler ile çok kısa zamanda ve büyük oranda doğrulukla radyasyonu tahmin etmişlerdir (Bilgiç ve Mert, 2021).

Meşecan ve ark. gerçekleştirdikleri çalışmada GprMax programından elde ettikleri simülasyon verilerini kullanarak gömülü nesneleri bulmak için üç aşamalı bir yöntem ile özellik vektörleri oluşturulmuştur. Özellik vektörü elde etmek için n-satır ortalama kullanarak ön işleme, görüntü ölçeklendirme ve ilgi alanını bir özellik vektörüne dönüştürme algoritmalarını kullanmıştır. Sınıflandırma algoritması olarak K En Yakın Komşuluk (K-EYK) kümeleme yöntemi kullanılarak %90.3'lük bir tespit performansı elde edilmiştir (Mesecan ve ark., 2020).

Riera ve ark. yapmış oldukları çalışmada yağmur damlalarının miktarının ve dağılımlarının, milimetre dalga boyunda EM dalgayı etkilediğini belirtmişlerdir. Yağmurun yağış şekillerine ve miktarına göre gözle görülür şekilde zayıflama olduğunu belirtmişlerdir. Sinyalin dalga boyuna bağlı olarak bu zayıflamanın miktarı değişse de her dalga boyunda zayıflama olacağını tespit etmişlerdir. Yağmurdan kaynaklanan zayıflamanın tahmin edilebilmesi için bir model önermişlerdir (Riera ve ark., 2021).

Pu ve ark. yaptıkları çalışmada meteorolojik faktörlerin EM dalganın yayılma gecikmesi üzerinde etkisi olduğunu tespit etmişlerdir. Toprak sıcaklığı, toprak nem değeri, atmosferik sıcaklık, atmosferik nem değerleri ve atmosferik basıncın yayılma gecikmesi üzerindeki etkilerini araştırmışlardır. Çalışmada 1000 km'lik bir yayılma mesafesi için yayılma gecikmesinin atmosfer şartlarından kaynaklı olarak yüz nano saniyeden mikro saniye mertebesine kadar değişebildiğini belirtmişlerdir (Pu ve ark., 2021).

Chakchak ve Çetin yapmış oldukları çalışmada global solar radyasyon tahminlerinde yapay sinir ağlarının kullanıldığını belirtmişleridir. Girdi olarak sıcaklık, basınç, nem kullanarak global solar radyasyonun tahminini yapmışlardır. Özellikle ANN hızlı ve başarılı sonuçlar vermesinden dolayı tercih edildiğini belirtmişlerdir. Sonuçların değerlendirilmesinde MAE ve MAPE değerleri göz önünde bulundurularak modelin tahmin doğrulukları değerlendirilmiştir (Chakchak ve Cetin, 2021).

3. MATERYAL VE YÖNTEM

3.1. Radarlar ve Elektromanyetik Teori

Radarlar çalışma prensibi olarak elektromanyetik (EM) dalgaların ortamda ilerlemesi ve hedefe çarparak geri yansıması prensibine göre çalışmaktadır. Sadece mesafe veya sadece hız ölçümü yapılan radar uygulamaları olduğu gibi hem mesafe hem de hız ölçümünün beraber yapıldığı uygulamalar da bulunmaktadır. Radarlar günümüzde askeri uygulamalardan sivil uygulamalara birçok farklı alanda kullanılmaktadır.

Askeri savunma alanında gözetleme, hedef takip ve füze güdüm gibi birçok amaçla radarlar aktif olarak kullanılmaktadır. Ayrıca radarların otonom sürüş gibi uygulamalarda da kullanımı giderek yaygınlaşmaktadır. Savunma ve otonom sürüş gibi uygulamalar için radar ölçümünde hassasiyet çok büyük öneme sahiptir.

Radar ile yapılan mesafe ölçümlerinde ortamın elektriksel parametreleri EM dalganın o ortamdaki hızını etkileyeceğinden dolayı ortam parametreleri hassas uygulamalar için önem arz etmektedir. Yere nüfuz eden radarlarda bu parametreler çok daha belirgin bir şekilde değiştiğinden EM dalganın hızı ışık hızı olarak alınmaz. Ancak hava ortamında EM dalganın hızının sabit ve ışık hızında olduğu varsayılır. Bu durumda hava koşullarının yağışlı olması gibi etkenlerle ortam parametrelerindeki değişimler EM dalganın hızını etkileyecek ve radar ile yapılan mesafe ölçümlerinin hassasiyetini bozacaktır. Bu nedenle bu tez çalışmasında olumsuz hava koşullarında EM dalganın hızındaki değişim araştırılmıştır.

Savunma radarları uzun mesafe ölçüm yapan radarlar olduğundan ortamın elektriksel özelliklerindeki küçük değişimlerin mesafe ölçümlerinde belirgin farklara neden olabileceği düşünülmektedir. Özellikle hava savunma radarlarında yapılan araştırmalarda hedef tutturma olasılıklarının %100 başarılı olmadığı görülmüştür. Güdümlü füze tarama ve arayıcı başlıklarda hedefin bulunarak takip edilmesi ve yok edilmesi için radarlar önemli bir bileşendir. Güdümlü füzeler, hedef noktasına varıncaya kadar uçuş hattı süresince yönlendirilebilen füzelerdir. Füze güdüm sistemi, füzenin gerçek uçuş yörüngesiyle hedefi vurmasını sağlayacak uçuş yörüngesini karşılaştırır ve hedefe yönlenmesi için gerekli komutları üretir. Bu tip sistemlerde hedefin konum hesabı için radarlar kullanılmaktadır (Neri, 2001; Mellen, 2000; Lin, 1991; Parker and Maurer, 1984). Yaklaşık olarak 4800 m/s hızla ilerleyen bir füzenin güdüm

sistemleri için küçük hatalar bile çok önemlidir (Giles, 2015). Örneğin 2019 yılının 9. ayında Amerikan patriot sistemleri tarafından korunan Suudi Aramco petrol rafinerisine düzenlenen hava saldırılarında patriot sistemleri bölgeyi koruyamayarak büyük bir felaket yaşanmasına sebep olmuştur (Anonim, 2019). 2018 yılında Amerika deniz kuvvetlerinin Suriye'ye karşı düzenlemiş olduğu füze saldırısında 103 cruise füzesinin hava savunma sistemi ile sadece 73 tanesi etkisiz hale getirilebilmiştir (Gözütok, 2018). Hassas uygulamalardan olan savunma sistemlerinde kullanılacak olan radarlarda ölçüm doğruluğu çok büyük önem arz etmektedir. Ayrıca günümüzde çok büyük bir hızla hayatımıza giren otonom araçlarda radarlar ile yapılacak ölçümlerde oluşacak küçük hatalar ciddi kazalara neden olacağından hava durumu parametrelerinin dikkate alınarak hesaplama yapılması gerekmektedir. Farklı hava koşullarının ölçümlerde dikkate alınması ile özellikle hassas uygulamalar için hata oranın düşürülerek olası kötü durumların önüne geçilmesine katkı sağlanacaktır.

3.1.1. Farklı ortamlarda elektromanyetik özellikler

Herhangi bir ortamın elektrik geçirgenlik hesabı Eşitlik 3.1'deki formül ile hesaplanır.

$$\varepsilon = \varepsilon_0 . \varepsilon_r \ (F/m) \qquad (3.1)$$

Eşitlik 3.1'de ε_0 vakum ortamın elektrik geçirgenliği, ε_r ise malzemenin dielektrik sabiti (bağıl elektrik geçirgenliği) olarak tanımlanmaktadır. Elektrik geçirgenlik (ε), malzemenin elektriksel kutuplanabilirliğinin bir ölçütü olarak tanımlanır.

Vakum ortamın elektrik geçirgenliği değeri Eşitlik 3.2 de gösterilmiştir.

$$\varepsilon_0 = \frac{10^{-9}}{36\pi} (F/m) \qquad (3.2)$$

EM dalganın malzeme içerisinde ilerleme hızı elektrik geçirgenliğine bağlı olarak değişir. Dielektrik sabitinin yüksek olduğu malzemelerde EM dalgalar daha

yavaş ilerler. Bundan dolayı radar dalgaları malzeme içerisinde ışık hızından daha yavaş ilerler.

Bir ortamın manyetik geçirgenliği (μ), manyetik alan içerisinde malzemenin manyetize olmasını sağlar ve Eşitlik 3.3'te gösterildiği gibi hesaplanır. Birimi Henry/metre (H/m) olarak ölçülür.

$$\mu = \mu_0 . \mu_r \ (H/m) \tag{3.3}$$

Eşitlik 3.3'te μ_0 boşluğun manyetik geçirgenliğidir ve değeri Eşitlik 3.4'te verilmiştir.

$$\mu_0 = 4\pi . 10^{-7} (H/m) \tag{3.4}$$

μ_r ise malzemenin bağıl manyetik geçirgenliğidir. Ferromanyetik malzemelerde (demir, nikel ve kobalt) μ_r>>1 olmaktadır. Ferromanyetik özellik göstermeyen malzemelerin bağıl manyetik geçirgenliği 1'e çok yakındır ve yaklaşık 1 olarak kabul edilir. Böylece bu tip malzemelerin manyetik geçirgenliği boşluğun manyetik geçirgenliğine eş değer varsayılır (Ma ve ark., 2018). μ_r>1 olanlarına paramanyetik (alüminyum, magnezyum, titanyum ve tungsten), μ_r<1 olanlarına ise diamanyetik (bakır, germanyum, gümüş ve altın) denilmektedir.

Radar uygulamalarında elektriksel iletkenlik, malzemenin iletim kabiliyetini gösteren bir özelliktir. σ sembolü ile gösterilir ve birimi S/m'dir. İletkenliği yüksek olan malzemeler EM dalganın iletimini zorlaştırır. Bu nedenle iletkenliği yüksek ortamda ilerleyen EM dalgada zayıflama ve dağılma gerçekleşir dolayısıyla EM dalga sadece sığ kesimlere nüfuz edebilir. İletkenliği düşük malzemelerde ise EM dalganın ilerleyişi kolaylaşacağından EM dalga daha derinlere nüfuz edebilir.

Kayıpsız ortamda yayılan EM dalga için Ampere yasası fazör formda Eşitlik 3.5'te görüldüğü gibi yazılır.

$$\nabla \times \overline{H} = j\omega\overline{D} = j\omega\varepsilon\overline{E} \tag{3.5}$$

Bu eşitlik, kayıplı ortamda yayılan EM dalga için Eşitlik 3.6'da görüldüğü gibi yazılır.

$$\nabla \times \bar{H} = \bar{J} + j\omega\bar{D} \quad (3.6)$$

$$\bar{J} = \sigma\bar{E} \quad (3.7)$$

Eşitlik 3.6 düzenlenerek aşağıdaki eşitlikler elde edilir.

$$\nabla \times \overline{H} = j\omega\left(\varepsilon - j\frac{\sigma}{\omega}\right)\bar{E} = j\omega\varepsilon_c\bar{E} \quad (3.8)$$

$$\varepsilon_c = \varepsilon - j\frac{\sigma}{\omega} = \varepsilon' - j\varepsilon'' \quad (3.9)$$

$$\varepsilon' = \varepsilon \quad (3.10)$$

$$\varepsilon'' = \sigma/\omega \quad (3.11)$$

$$tan\delta_c = \frac{\varepsilon''}{\varepsilon\prime} = \frac{\sigma}{\omega}\cdot\frac{1}{\varepsilon'} = \frac{\sigma}{\omega\varepsilon} \quad (3.12)$$

Eşitlik 3.12'de elde edilen denklem kayıp tanjantı olarak tanımlanır. Burada δ_c, kayıp açısı olarak ifade edilir. Kayıp tanjantının 0'a eşit olmasına ya da 1'den çok küçük ya da çok büyük olmasına göre 3 farklı durum için EM dalganın hız hesaplama denklemleri değişecektir. Aşağıda bu 3 farklı durum için EM dalganın hız hesaplamaları verilmiştir.

3.1.1.1. Kayıpsız ortamlarda EM dalganın hızı

Kayıpsız ortam için öziletkenlik (σ) değeri (yani kayıp tanjantı) 0 olacağından EM dalganın hızını ifade eden denklem Eşitlik 3.13'te olduğu gibi ifade edilebilir.

$$u = \frac{1}{\sqrt{\mu\varepsilon}} \quad (3.13)$$

Hava ortamında veya uzay boşluğunda EM dalganın hızını hesaplarken bu eşitlik kullanılmakta ve sonuç olarak ışık hızına eşit bir değer hesaplanmaktadır.

3.1.1.2. İyi iletken ortamlarda EM dalganın hızı

İyi iletken ortamlarda kayıp tanjantı $\frac{\sigma}{\omega.\varepsilon} \gg 1$ olmaktadır ve bu durum için EM dalganın hızı Eşitlik 3.14 ile hesaplanmaktır.

$$u = \sqrt{\frac{2\omega}{\mu\sigma}} \tag{3.14}$$

Burada ω EM dalganın açısal frekansını, σ ise ortamın öziletkenlik değerini ifade etmektedir. İyi iletken ortamlarda EM dalganın hızı düşük olmaktadır.

3.1.1.3. Az kayıplı ortamlarda EM dalganın hızı

Az kayıplı ortamlarda kayıp tanjantı $\frac{\sigma}{\omega.\varepsilon} \ll 1$ olmaktadır. Bu ortamlarda EM dalganın hızı Eşitlik 3.15'te verildiği şekilde hesaplanmaktadır.

$$u = \frac{1}{\sqrt{\mu\varepsilon}}\left[1 - \frac{1}{8}\left(\frac{\sigma}{\omega\varepsilon}\right)^2\right] \tag{3.15}$$

Eşitliklerde görüldüğü üzere her ortamın manyetik ve elektrik geçirgenlikleri ve öziletkenlik değeri farklı olacağından EM dalganın hızı ortamdan ortama farklılık gösterecektir. Ancak özellikle hava ortamını kullanarak yapılan radar çalışmalarında bu etki dikkate alınmamaktadır. Halbuki yağışlı ortamlarda ve kötü hava koşullarında havanın elektrik parametreleri değişeceğinden EM dalganın hızı değişecek (azalacak) ve dolayısıyla radar mesafe ölçümleri de buna bağlı olarak sapacaktır.

Çizelge 3.1'de farklı dielektrik sabitine ve öziletkenlik değerine sahip bazı materyaller (ortamlar) için 1 GHz frekanslı bir EM dalganın hesaplanan hız değerleri görülmektedir (Milsom, 2003).

Çizelge 3.1. Bazı malzemeler için 1GHz'de radar parametre değerleri (Milsom, 2003)

	Elektriksel İletkenlik (S/m)	Dielektrik Sabiti	Faz Hızı (m/µs)
Ortamın Malzemesi	**σ**	$\boldsymbol{\varepsilon_r}$	**u**
Boşluk	0	1	299.8
Deniz Suyu	3.3	80	32
Kayaç	10^{-4}	5	134
Kuru Kum	10^{-3}	4	150
Islak Kum	10^{-2}	25	60

Çizelge 3.1'de görüldüğü üzere farklı dielektrik sabiti ve öz iletkenlik değerine sahip ortamlarda EM dalga yayılım hızları da farklılık göstermektedir. Buna bağlı olarak radar mesafe hesaplamalarında EM dalganın hızının ortam şartlarına göre değiştiği açıkça görülmektedir.

Bu durumun olumsuz hava koşullarında hava ortamında da karşılaşıldığı ve araştırılmaya açık bir problem olduğu için bu tez çalışmasında sabit mesafedeki bir hedefin radar ile ölçümlerinde gözlenen değişimin hava parametreleri ile ilişkisi kurulmaya çalışılmıştır. Radar tarafından ölçülen mesafe verileri geliştirilen bir uygulama vasıtası ile radardan bir bilgisayar kullanarak seri port üzerinden okunmuştur. Hava durumu verileri ise yaygın olarak kullanılan bir anlık hava tahmin yayını uygulaması olan Accuweather üzerinden XML ile geliştirilen uygulama aracılığı ile alınmıştır. Mesafe ve hava durumu verileri geliştirilen uygulama üzerinden bilgisayara kurulan SQL server üzerine kaydedilmiştir. Daha sonra alınan veriler analiz edilmiştir.

3.2. Kötü Hava Koşullarında Radar Mesafe Hatalarının Tespit Edilmesi

Hava durumunun değişimi nedeniyle EM dalganın hızında oluşan değişimlerin etkisiyle radar mesafe ölçümlerindeki hataların belirlenebilmesi için Şekil 3.1'deki deney düzeneği kurulmuştur.

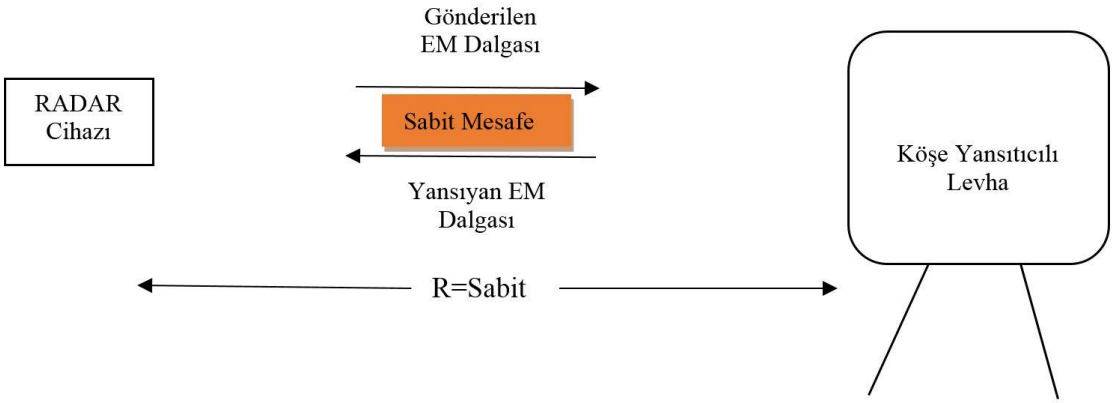

Şekil 3.1. Temel deney düzeneği

Şekil 3.1'de hedef sabit bir noktada bulunduğundan radar ile elde edilen mesafe ölçümünün hep aynı değerde olması beklenmektedir. Fakat uzun vadede hava koşullarının değişimi ile mesafe ölçümlerindeki sapmaların tespiti gerçekleştirilmiştir.

Böylece hava durumu verilerini de kullanarak radar mesafe hatalarını tahmin eden bir model ortaya koyulmuştur.

3.2.1. Deney düzeneği

Geliştirilen deney düzeneğinde sabit mesafede yerleştirilen bir adet köşe yansıtıcı, sürekli olarak sinyal gönderip alan radar ve bir adet bilgisayar kullanılmıştır. Bilgisayar üzerinde geliştirilen bir yazılım aracılığı ile bir veri tabanına erişim sağlanarak verilerin düzenli bir şekilde kaydedilmesi sağlanmıştır. Bu uygulama sayesinde RS232 USB dönüştürücü aracılığıyla radardan gelen veriler doğrudan okunmuştur. Radar verilerinin okunması esnasında hava durumu verileri de Accuweather uygulaması üzerinden XML kullanılarak okunmuştur. Ayrıca ölçüm yapılan anına ait tarih ve saat bilgileri de veri tabanına kaydedilmiştir. Böylece verilerin hepsinin düzenli bir şekilde kayıt altına alınması sağlanmıştır.

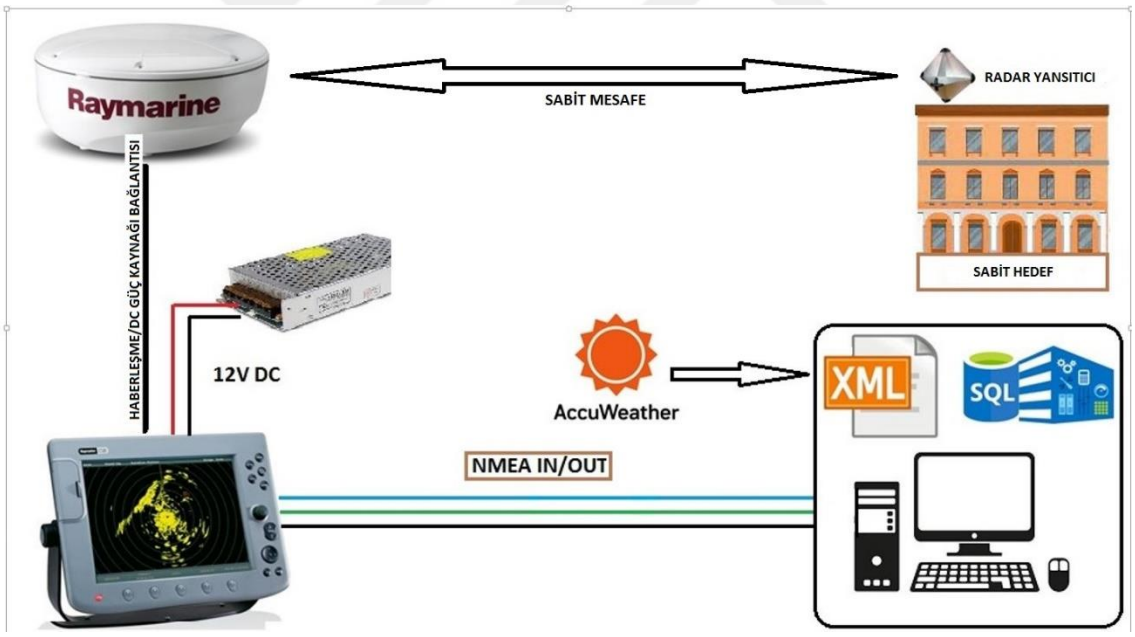

Şekil 3.2. Kurulumu yapılan deney düzeneği

Şekil 3.2'de detaylarıyla görülen deney düzeneği oluşturulmuştur. Deney düzeneğinde radar ölçümleri için Raymarine marka RD218 model bir radar kullanılmıştır. Radar verilerinin gözlemlenmesi ve yorumlanabilmesi için C120 model bir ekran ünitesi kullanılmıştır. Ayrıca bu düzeneğe gerekli olan DC gerilimin sağlanması için 12V 10A'lik bir SMPS güç kaynağı kullanılmıştır.

3.2.1.1. Raymarine RD218 model radar

Şekil 3.3'te ölçümler için kullanılan radarın anten ve elektronik kısımlarını barındıran temel ölçüm ünitesi görülmektedir.

Şekil 3.3. Raymarine RD218 radar dome

Bu ünitenin içerisinde anten, RF gücünü üreten magnetron, antenin 360 derece dönmesini sağlayan ve ölçüm açısını kaydeden düzenek ve analog ölçümü gerçekleştiren kısımlar Şekil 3.4'te görülmektedir.

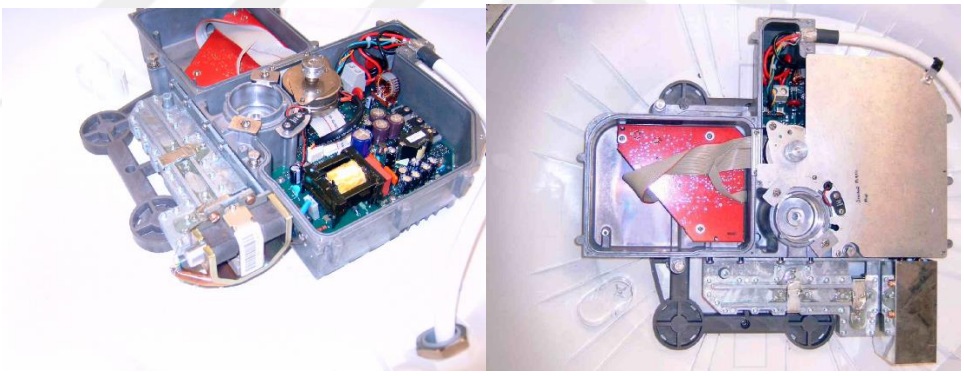

Şekil 3.4. Raymarine RD218 iç yapısı

Tam tur tarama yapabilmek için döndürülerek kullanılan dizi yama anten Şekil 3.5'te görülmektedir.

Şekil 3.5. Raymarine RD218 dizi yama anten

Motora bağlı olan dizi yama anten 360 derece dönüş yaparak tam bir tarama sağlamaktadır. Böylece hedefin mesafesinin yanında açısal olarak yerinin gösterilmesini de sağlamaktadır. Radar içerisinde yapılan ölçümlerin C120 ekran ünitesine aktarılması için Şekil 3.6'da gösterilen bağlantılar kullanılmaktadır.

Kullanılan radarın teknik özellikleri Çizelge 3.2'de verilmiştir.

Çizelge 3.2. Radar sisteminin teknik özellikleri

Verici

Verici Frekansı	9410 +/– 30 MHz Pik
Verici	Solid-state modulator sürücülü Magnetron
Pik Çıkış Gücü	4.0 kW (nominal)

Anten

Anten Tipi	Yama Dizi
Beam Width	4.5° yatay, 25° dikey
Polarizasyon	Horizontal
Dönüş Hızı	24 rpm (nominal)

Alıcı

Ara Frekans (IF)	60 MHz (nominal)
Alıcı Karakteristiği	Logaritmik
Alıcı Gürültü	5 dB'den daha az
Alıcı Bant Genişliği	12/3/0.7/0.5 MHz

Darbe Genişliği/PRF (nm)	**Darbe Uzunluğu (ns)**	**PRF (kHz)**
0.25 ya da daha az	75	3.0
0.50	100	3.0
0.75	150	3.0
0.75 genişletilmiş	250	2.5
1.50	350	1.8
3.00	450	1.4
3.00 genişletilmiş	600	1.0
6.00 ya da daha fazla	1000	0.74

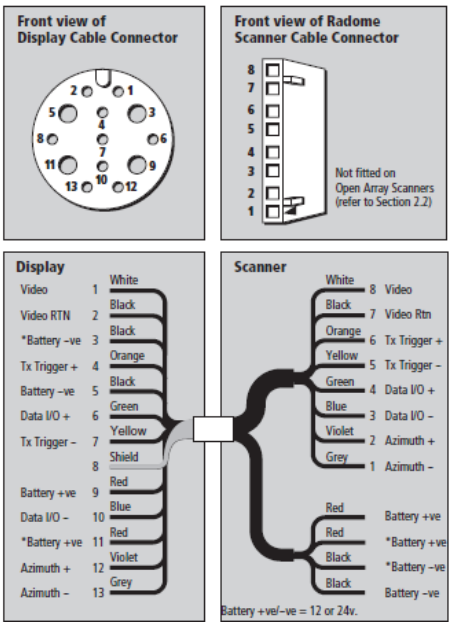

Şekil 3.6. Raymarine RD218 bağlantı şeması

Radarın ölçüm yapılacak çatı üzerine kurulmuş hali Şekil 3.7'de görülmektedir.

Şekil 3.7. Radarın kurulumunun tamamlanmış hali

3.2.1.2. C120 ekran ünitesi

Radardan gelen verilerin analiz edilmesi ve gösterilmesi için C120 ekran ünitesi kullanılmıştır. Şekil 3.8'de kullanılan ekran ünitesi görülmektedir.

Şekil 3.8. C120 ekran ünitesi

Radar ile bağlantısını kurmak için C120 ekran ünitesinin arkasında Şekil 3.9'da görülen girişler kullanılmıştır.

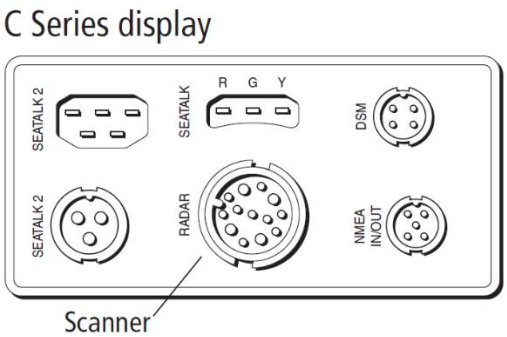

Şekil 3.9. C120 ekran ünitesi girişleri

3.2.1.3. Güç kaynağı

Radar sisteminin güç beslemesi Şekil 3.10'da görülen AC/DC dönüştürücü bir SMPS güç kaynağı kullanılmıştır.

Şekil 3.10. Sistemde kullanılan güç kaynağı

Güç kaynağının girişi AC 220V, çıkışı DC 12V (10 amper'e kadar) özelliktedir. Ayrıca olası kısa devre anında sistemi korumak amacıyla otomatik kapanma özelliğine sahiptir. Bunun yanında sistem 7/24 esasına uygun çalışacağından aşırı akım ve termal koruma özelliği bulunması da deney düzeneğinde kullanılmasında önemli bir faktördür. Ayrıca sistem için 4A'lik akım yeterli olmasına rağmen uzun süreli kullanım esnasında problem yaşanmaması için 10A'lik özellikte güç kaynağı seçilmiştir.

Güç kaynağı C120 ekran ünitesine bağlanmıştır. Radar ünitesi ise C120 ekran ünitesinden beslenmektedir.

3.2.1.3 Köşe yansıtıcı

Küçük yansıtma yüzeyine sahip köşe yansıtıcılar, nesnelerden güçlü radar yansıması elde etmek için kullanılırlar. Köşe yansıtıcılar birbirlerine 90°'lik açı ile yerleştirilmiş, elektriksel iletkenliği yüksek malzemeden imal edilmiş iki veya üç adet plakadan meydana gelirler. Gelen EM dalgalar birkaç yansımaya uğrayarak geldikleri yöne yansıtılırlar. Böylece küçük bir yansıtma yüzeyine sahip bir nesneden çok kuvvetli bir yansıma elde edilebilir.

Köşe yansıtıcılarda kullanılan yüzeylerin boyutları gelen işaretin dalga boyuna göre daha büyük olmalıdır. Köşe yansıtıcı ne kadar büyük olursa, yansıtılan enerji de o kadar artacaktır. Sistemde kullanılan köşe yansıtıcı Şekil 3.11'de görülmektedir.

Şekil 3.11. Deney düzeneğinde kullanılan köşe yansıtıcı

Kullanılan köşe yansıtıcının ölçüleri 28x28 cm boyutlarındadır. Kullanılan köşe yansıtıcının radar kesit alanı Eşitlik 3.16'da verildiği şekilde hesaplanmaktadır.

$$RKA = \frac{4 \cdot \pi \cdot a}{3 \cdot \lambda^2} \qquad (3.16)$$

Eşitlikte a yansıtıcının kenar uzunluğu, λ ise radardan yayılan dalganın dalga boyu olarak tanımlanmaktadır.

3.3. Deneysel Düzeneğin Çalışması

Çalışmada kullanılan radar, ölçüm süresi boyunca belirli aralıklarla sabit konumda bulunan hedefin mesafesini ölçmektedir. Mesafe ölçümleri yapılırken aynı anda o andaki hava koşulları alınarak mesafe ve hava koşulları arasındaki bağlantı saptanmaya çalışılmaktadır. Ölçümler sırasında havanın nemi, sıcaklığı, hissedilen sıcaklığı ve basınç değerleri kayıt altına alınmıştır. Radar verileri seri port üzerinden alınarak sisteme kaydedilmiştir. Verilerin kaydedilmesi için üzerinde Microsoft SQL server kurulu bir bilgisayar kullanılmıştır. Ayrıca bir uygulama geliştirilerek sistem verilerinin belirli zaman aralıklarında periyodik olarak alınıp veri tabanı üzerine kaydedilmesi için kullanılmıştır. Uygulama, C# programlama dili kullanılarak geliştirilmiştir. Uygulama aynı zamanda açık kaynaklı bir XML uygulaması olan Accuweather üzerinden hava verilerini de alarak kayıt altına almaktadır. Hassas bir sonuç elde edebilmek adına 2 dakikada bir radar mesafe ölçümleri ve hava verileri alınarak veri tabanına kayıt işlemleri yapılmıştır.

Deney düzeneği Şekil 3.2'de olduğu gibi kurularak çalıştırılmıştır. Radar çalıştırıldığında radar ekranı üzerinde yakalanan hedeflerin ekran çıktısı Şekil 3.12'de görülmektedir.

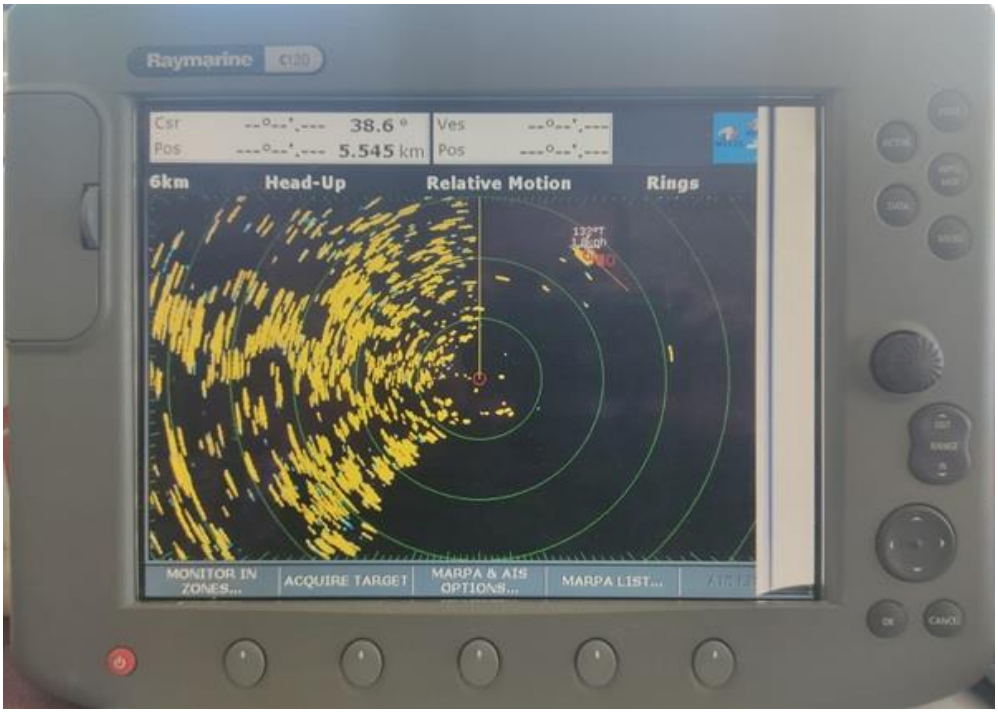

Şekil 3.12. Radar ile yakalanan hedeflerin ekran çıktısı

Kullanılan radarda Target Tracking Mode (TTM) özelliği bulunmaktadır. Bu özellik ile radarın sabit mesafede bulunan hedefi takip etmesi sağlanmıştır. Şekil 3.13'te TTM modu ile takip edilen bir hedefin radar ekran çıktıları görülmektedir.

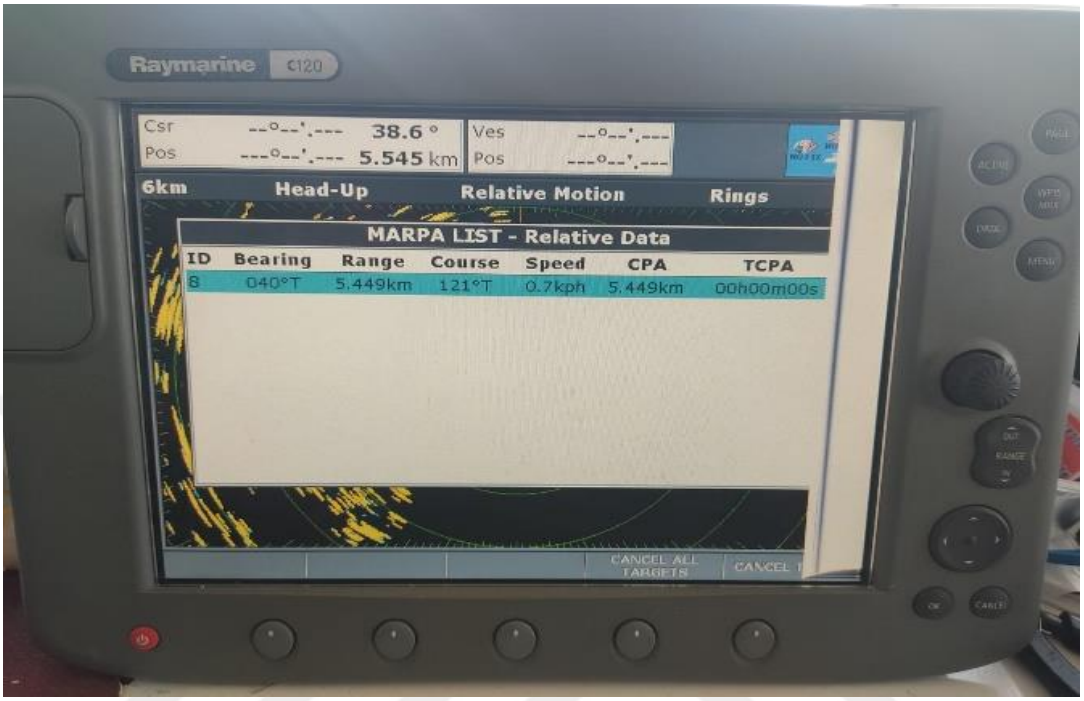

Şekil 3.13. TTM mod ile takip edilen bir hedefin ekran çıktısı

Radar ile bilgisayar bağlantısı C120 ekran ünitesinin arkasında bulunan ve istenilen verileri NMEA formatında gönderebilen RS232 bağlantısı ile gerçekleştirilmiştir. İstenilen verilerin C120 ekran ünitesi üzerinden gerekli ayarlamalar yapılarak NMEA çıktı ekranından takip edilen hedefin verilerinin gönderimi sağlanmıştır. Mesafe verilerinin alınabilmesi için bilgisayar tarafında USB–RS232 dönüştürücü kullanılmıştır. Böylece NMEA formatındaki veriler bilgisayar üzerindeki bir USB portu sayesinde okunmuştur. Geliştirilen uygulamada COM port üzerinde bir kesme oluşturularak verilerin okunması sağlanmıştır. Radarda her tarama gerçekleştiğinde oluşan TTM verisi kesme sayesinde yakalanmaktadır. Sistem kurgusu yapılırken belirlenen 2 dakikalık süre dolduğunda bufferda bulunan güncel TTM verisi SQL Server üzerine kaydedilmektedir. Mesafe verileri 2 dakikada bir, geliştirilen uygulama ile USB portundan alınarak veri tabanı üzerine kaydedilmiştir. Hava durumu verilerinin alınması benzer şekilde geliştirilen uygulama ile XML üzerinden gerçekleştirilmiştir. Radar üzerinden her bir mesafe verisi alındığında aynı zamanda Accuweather uygulaması üzerinden XML sorgusu yapılarak ölçüm yapılan konumun

anlık hava durumu verileri okunarak kayıt altına alınmıştır. Accuweather uygulaması için önce hava durumu verilerinin alınması istenen yer ile beraber sistem üzerine kayıt yapılmıştır. Kayıt yapıldıktan sonra sistem bir api key oluşturmuştur. Bu api key ile XML üzerinden hava durumu sorguları yapılmıştır.

Böylece deneysel düzenek çalışır hale getirilmiş ve hava durumu verilerinden sıcaklık, hissedilen sıcaklık, nem ve basınç verileri ile beraber radardan mesafe verisi okunmaya başlanmıştır. Ölçümler her 2 dakikada bir tekrarlanacak şekilde yapılmıştır. Yapılan bu ölçümler ile beraber ölçüm yapılan tarih ve saat bilgileri de kayıt altına alınmıştır.

Ölçüm yapılırken hava parametrelerinin çok geniş bir aralıkta olması için farklı günlerde ve çok farklı hava şartlarında ölçümler yapılmıştır.

3.4. Verilerin Toplanması ve Analizi

Kurulumu tamamlanan deneysel düzenek aracılığıyla farklı gün ve hava koşullarında 2 dakikada bir veri almak üzere toplam 11223 adet veri kaydedilerek büyük bir veri seti oluşturulmuştur. Bu veri setinin analiz edilmesi için MLR, SVM, ANFIS, KNN ve ANN yöntemleri kullanılarak bazı çalışmalar yapılmıştır.

Kullanılan yöntemlerden MLR ve SVM daha çok doğrusal regresyon analizi yaparak girdi verileri ile çıktı verisi arasında bağıntıları bulmakta kullanılmaktadır. Bu yöntemler, karmaşık olan bağıntılarda yapay sinir ağlarına göre daha zayıftır. KNN yöntemi ise yakın komşuluklara bakarak tahmin yapmaktadır. ANFIS yöntemi hem bulanık mantık hem de yapay sinir ağlarını kullanarak tahmin yapan ve yaygın olarak kullanılan bir yöntemdir. ANN yöntemi ise tamamen yapay sinir ağlarını kullanarak tahmin yapan ve ANFIS gibi karmaşık tahminlerde çok yaygın kullanılan bir yöntemdir. ANFIS ve ANN sonuç hesaplamaları diğer yöntemlerle kıyaslandığında daha uzun sürmektedir.

3.4.1. Çoklu doğrusal regresyon (Multiple Linear Regression, MLR)

Doğrusal Regresyon bir adet bağımlı değişken ile bununla ilişkisi olan bir dizi bağımsız değişken arasındaki ilişkiyi ortaya koymak için yapılan analizdir.

Çoklu doğrusal regresyon ise Doğrusal Regresyondan farklı olarak iki ve daha fazla bağımsız değişken ve bir adet bağımlı değişken arasındaki doğrusal bağıntıyı

inceler. Çoklu doğrusal regresyon analizinde bağımlı ve bağımsız değişkenler arasında doğrudan bir bağıntı vardır. Bu bağıntı Eşitlik 3.17'de görüldüğü gibi ifade edilebilir.

$$Y=XB+E \tag{3.17}$$

Eşitlik 3.8'de Y, bağımlı değişken gözlem vektörü, X bağımsız değişkenler gözlem matrisi, B katsayılar vektörü ve E rasgele hata vektörü olarak tanımlanır. Verilere çoklu regresyon uygulanabilmesi için, bağımsız değişkenler arasında çoklu bağımlılığın (multicollinearity) bulunmaması gerekir. Bağımlı değişken sayısının iki ve daha fazla olduğu durumlarda çok değişkenli doğrusal regresyon analizi çoklu doğrusal regresyon analizinin yinelenmiş biçimi olarak tanımlanır. Parametre tahminleri ve modelin geçerliliğini belirlemek için gerekli kareler toplamlarının hesaplanması çoklu regresyon yöntemi ile benzerlik gösteren bir özelliğidir.

3.4.2. Destek vektör makineleri-regresyon (Support Vector Machine –Regression SVM-R)

Destek Vektör Makineleri (SVM) sınıflandırma için kullanılabilir. Konvolüsyon katmanları özellik çıkarma işlemini gerçekleştirir. Sınıflandırma katmanında SVM algoritması yerleştirilir (Özkaya, 2020).

SVM, verileri girdi olarak almak ve istenen formata dönüştürmek için içerisindeki çekirdekleri kullanır. Çekirdekler girdi verilerini uygun bir özellik alanında iki nokta arasında döndürür. Böylece, çok yüksek boyutlu alanlarda bile hesaplama maliyeti düşük olur. SVM, Radyal Temel Fonksiyon (RTF), polinom veya sigmoid gibi farklı çekirdek fonksiyonlarına sahiptir. RTF çekirdeğinin formülü Eşitlik 3.18'de verilmiştir.

$$KK_{(x,x')} = \exp\left(\frac{||x-x^{\wedge\prime}||^2}{2\sigma^2}\right) \tag{3.18}$$

Bazı giriş uzaylarındaki özellik vektörlerini temsil eden x ve x' örneğindeki RTF çekirdeği, iki özellik vektörü arasındaki karesel Öklid mesafesi olarak tanımlanır. σ ise örnekler arasındaki varyansı gösterir.

SVM sınıflandırması için RTF çekirdeğini uygularken, g ve C olmak üzere iki parametre vardır. Sezgisel olarak, g parametresi, tek bir eğitim örneğinin etkisinin "uzak" anlamına gelen düşük değerlere ve "yakın" anlamına gelen yüksek değerlere ne kadar ulaştığını tanımlar. C parametresi, karar fonksiyonunun büyüklüğünü maksimize etmeye karşı eğitim örneklerinin doğru bir şekilde sınıflandırılmasını sağlar. Doğruluk için en iyi parametreleri bulmak amacıyla hem g hem de C parametrelerinde grid arama yöntemi uygulanır. g parametresi 0.01 ile 1 arasında, C parametresi ise 0.1 ve 10 arasında değer alabilir. Optimal değerler, sırasıyla 0.1 ve 1'dir (Cherkassky ve Ma, 2004).

Bu çalışmada SVM'nin bir alt kırılımı olan SVM-Regresyon metodu kullanılarak hatalar tahmin edilmiştir.

3.4.3. Bulanık çıkarım sistemi (Adaptive Neuro Fuzzy Inference System, ANFIS)

Bulanık mantık sistemleri insanların düşünsel yapısı göz önünde bulundurularak geliştirilmiş sistemlerdir. Bulanık mantık uygulamasında herhangi bir olaya 1 veya 0 gibi bir yaklaşım sergilemek yerine belli üyelik dereceleri ile yaklaşılmaktadır. Bu sistemler ortaya çıktıktan sonra literatürde veri işleme, tahmin, sistem kontrolü, modelleme vb. çok farklı alanda uygulanmışlardır. Literatürde Sugeno, Mamdani, Şen, Tsukamato gibi farklı çıkarım sistemleri türetilmiş ve kullanılmıştır. Mamdani ve Sugeno bu sistemlerin en yaygın kullanılanlarıdır. Mamdani bulanık çıkarım sisteminin giriş ve çıkış parametreleri üyelik fonksiyonlarından oluşmaktadır. Çıkış parametreleri üyelik fonksiyonlarından oluştuğu için durulaştırma adımına ihtiyaç duymaktadır. Sugeno bulanık çıkarım sistemi ise hesap yükü daha az olan bir sistemdir ve çıkış parametreleri sabit veya doğrusal olarak seçilebilir. Çıkış parametreleri üyelik fonksiyonu barındırmadığı için tekrar durulaştırma işlemine ihtiyaç duymamaktadır. Sugeno bulanık çıkarım sistemi, çıkış parametrelerinin doğrusal veya sabit olmasından kaynaklı olarak daha az matematiksel yük içerdiğinden daha yaygın olarak kullanılmaktadır. Ne var ki, çıkış parametreleri üyelik fonksiyonları şeklinde olan Mamdani bulanık çıkarım sisteminin parametrelerinin eğitimi daha zor olmaktadır ve kullanım alanı daha kısıtlı kalmıştır (Öztürk, 2022). Bu çalışmada Sugeno ANFIS yöntemi kullanarak girdi sonuçlarına göre radar mesafe hata verisi tahmin edilmeye çalışılmıştır.

Şekil 3.14'te ANFIS yapısı görülmektedir. Arada bulunan katman sayısı artırılarak sonuçların daha yüksek bir başarı oranı ile tahmin edilmesi mümkündür. Bu çalışmada ANFIS yöntemi ile en yüksek doğrulukta tahmin elde edilene kadar katman sayısı arttırılarak sonuçlar elde edilmiştir.

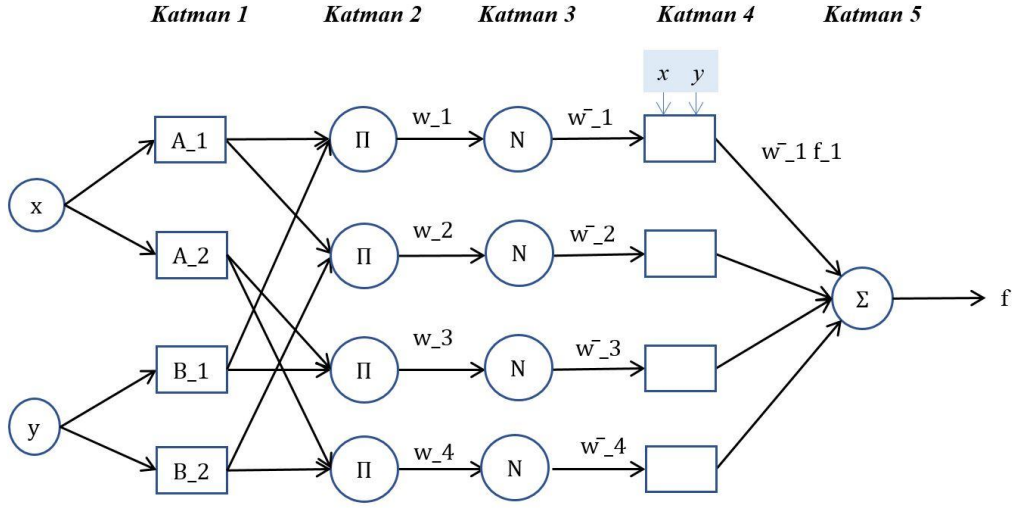

Şekil 3.14. ANFIS Yapısı (Öztürk, 2022)

3.4.4. K-En yakın komşu algoritması (K-Nearest Neighbors, KNN)

KNN bir veri setinde verilerin birbirleri arasındaki komşuluklarına bakarak tahmini gerçekleştiren bir algoritmadır. KNN algoritması; veriler arasında kümeleme işlemi gerçekleştirerek hesaplamayı yapmaktadır. Hesaplama yapılırken veriler arasındaki komşuluk oranı kullanıcı tarafından belirlenir. Veri seti içerisinde birbirine benzerlik gösteren veriler için komşuluk oranı yüksek, benzer olmayan verilerde komşuluk oranı düşük olacaktır. Veriler arasındaki uzaklık miktarına göre komşuluk oranları değişmektedir. Kullanıcının belirlediği komşuluk sayısına göre KNN algoritması sınıflama işlemini gerçekleştirir.

KNN algoritması kümeleme işleminde özellikler üzerinde ağırlıklandırma gerçekleştirilebilir. Eşitlik 3.10'da ağırlıkların tersi ya da tersinin karesinden yararlanılır. Güncel ağırlık değerlerine göre sınıflama işlemi yapılır. x_i eğitim verilerini, x_q test verilerini gösterir. Eşitlik 3.19'da atanan ağırlık değerlerine göre veriler en yakın komşuluk formuna dönüştürülebilir.

$$W=\frac{1}{d(x_q,x_i)^2} \tag{3.19}$$

KNN kümeleme algoritması için veri boyutu dikkate alınır ve en yakın komşuluklar incelenir. K, algoritmanın kullanacağı komşuluk sayısını ifade eder. K=1 durumu için en yakın komşuya bakılarak veri değerlendirilerek kümeleme işlemi yapılır. Diğer bir ifadeyle K değeri kaç adet komşuluğun kümeleme için kullanılacağını ifade eder. Şekil 3.15'te K=4 için K-en yakın komşuluk algoritma sınıflandırması yer almaktadır.

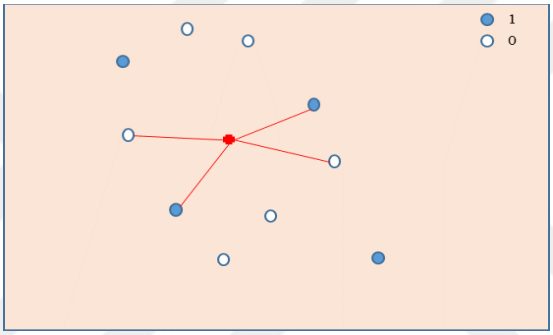

Şekil 3.15. K=4 için KNN algoritma sınıflaması (Özkaya, 2020)

3.4.5. Yapay sinir ağları (Artificial Neural Networks, ANN)

Yapay Sinir Ağları (ANN), insan beyninin fonksiyonlarını modelleme (öğrenme, genelleme) ve simüle etmek için tasarlanmış bir sistem olarak tanımlanabilir. ANN, beyindeki birbirine bağlı sinir hücreleri gibi yapay sinir hücrelerinden oluşur. Yapay sinir ağları, tahmin problemlerinde kullanılmaktadır (Xiong ve ark., 2014).

Birbiri ile ilişkili milyonlarca nörona sahip insan beyninin davranışlarının bilimsel olarak tanımlanması önemli bir hedef olmuştur ve hala tam olarak ortaya koyulmamıştır. İnsan sinir sisteminin bir modellemesi olan yapay sinir ağları biyolojik nöron hücre yapısı model alınarak geliştirilmiştir. Yapay sinir ağları, sezgisel yapıları sayesinde birçok mühendislik ve tıp alanında kullanılmaktadır (Gürsoy, 2018; Erkaymaz, 2014). İnsan beyin fonksiyonlarını taklit eden ANN; öğrenme, sınıflandırma, veriler arasında ilişkilendirme, genelleme, optimizasyon gibi konularda başarılı sonuçlar elde eden bir bilgisayar sistemidir (Öztemel, 2012).

3.4.5.1 ANN'nin Tarihsel Gelişimi

ANN 1943'te McCulloch ve Pitts tarafından yapılan çalışmalarda nöronların matematiksel bir modeli olarak ifade edilmiştir. Yapay sinir ağları matematiksel modeli incelendiğinde veriler ağ boyunca bir seviye değerinde iletilir ya da sönümlenir. Hebb 1949'da yapmış olduğu çalışmada aynı anda birden çok yapay sinir hücresi arasındaki bağlantının etkinliğini arttırmak için bir öğrenme algoritması geliştirmiştir. Hebb'in geliştirmiş olduğu bu algoritma ile birçok öğrenme kuralı için temel oluşturmuştur. Daha sonra Rosenblatt 1958 yılında McCulloch ve Pitts'in daha önce ortaya koydukları modeli geliştirerek modern bir ANN modelinin temelini oluşturan perceptron (algılayıcı) adı verilen yeni bir matematiksel modeli ortaya koymuşlardır. Algılayıcı, gelen sinyal verisini anlaşılabilir hale getirebilmek için, -1 ile +1 arasında değişen bir çıkış verisi üretmektedir (Rosenblatt, 1958). 1969 yılına gelindiğinde ise Miksy ve Paperttek tarafından tek katmanlı algılayıcı ANN modelinin XOR problemleri için bir çözüm üretemediği tespit edildiğinden katmanlı ANN bilimsel alanda popülerliğini kaybederek gelişimi durmuştur (Minsky ve Papert, 1969). J.J. Hopfield 1982 yılında ise optimizasyon ile alakalı problemleri çözebilmek adına tek katman ve geri besleme kullanan yeni bir yapay sinir ağı modeli geliştirmiştir (Hopfield, 1982). Daha sonra Rumelhart ve McClelland, 1989 yılında ANN'nin çıkış hatalarını azaltan "geri yayılım algoritmasını" ortaya koymuşlardır (Rumelhart ve McClelland, 1989). Geri yayılım algoritması birçok ANN uygulaması için temel öğrenme yöntemi olarak kullanılmaktadır (İçel, 2019).

3.4.5.2 Biyolojik sinir hücresi yapısı

Karmaşık bir yapısı olan hücresel biyolojik sinir ağı hücrelerine nöron denir. Biyolojik bir nöron Şekil 3.16'da gösterilmektedir. Bir sinir sisteminde beyinde, sinapslardan aksonlara doğru, kodlanmış bir bilgi akışı (elektrokimyasal) iletimi bulunmaktadır. Bir sinir hücresinde her bir nöronun aksonu diğer nöron hücresinin nöronlarına bilgi iletmekle görevlidir. Nöron, sinapslardaki çok sayıda diğer nöronlardan bilgi alır. Her bir nöronun, diğer nöronlardan 10000 den daha fazla uyaran aldığı tahmin edilmektedir. Nöron grupları alt sistemler halinde organize edilirler. Bu alt sistemlerin birleşmesiyle ise beyin meydana gelir. İnsan beyninin yaklaşık olarak

birbirine bağlanmış 100 milyar nörona sahip olduğu tahmin edilmektedir (Ayan ve Mehtap, 2018; Kalogirou, 2001).

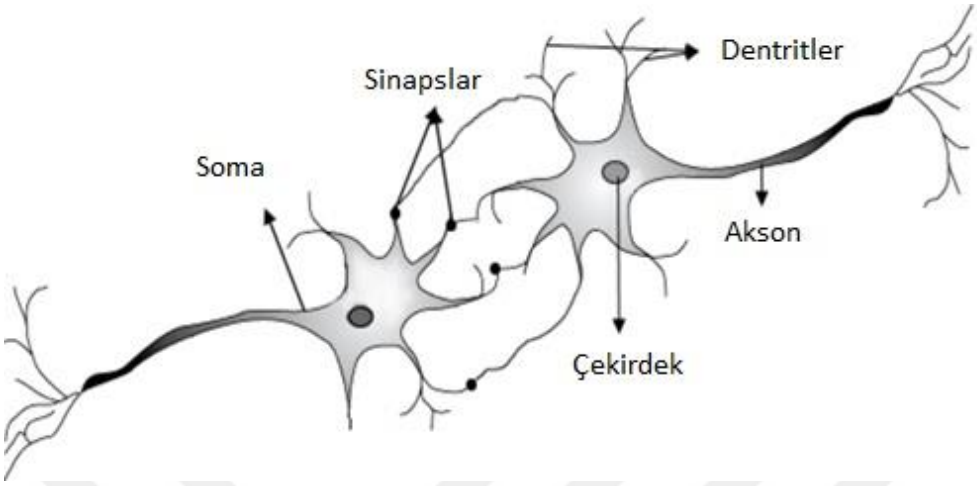

Şekil 3.16. Biyolojik bir nöronun basitleştirilmiş modeli (Gürsoy, 2018)

Biyolojik sinir sistemi, bilgiyi alan, yorumlayan ve bu bilgiye uygun olarak bir karar üreten merkezi sinir ağının bulunduğu ve temel olarak üç katmanlı bir sistemden oluşmaktadır. Bu yapı Şekil 3.17'de gösterilmektedir.

Şekil 3.17. Biyolojik sinir sisteminin blok diyagramı (Saraç, 2004)

Biyolojik sinir hücreleri için, alıcılar (receptors), organizma içinden veya dışarıdan algılanan uyarıları, merkezi sinir sistemine veri olarak ileten elektriksel sinyallere dönüştürmektedirler. Tepki sinirleri ise, merkezi sinir sistemi tarafından üretilen elektriksel sinyalleri organizmanın çıktısı olarak hareketlere dönüştürmektedirler. Merkezi sinir ağı, alıcı, tepki sinirleri ile ileri ve geri besleme olarak değerlendirilerek uyarılara uygun tepkilerin üretilmesi sağlanmaktadır. Yaygın olarak kullanılan çok katmanlı yapay sinir ağı mimarisinin örnek bir diyagramı Şekil 3.18'de gösterilmektedir. Ağ genelde bir girdi katmanı, gizli katman ve çıktı katmanı olmak üzere toplamda üç ana katmandan oluşmaktadır.

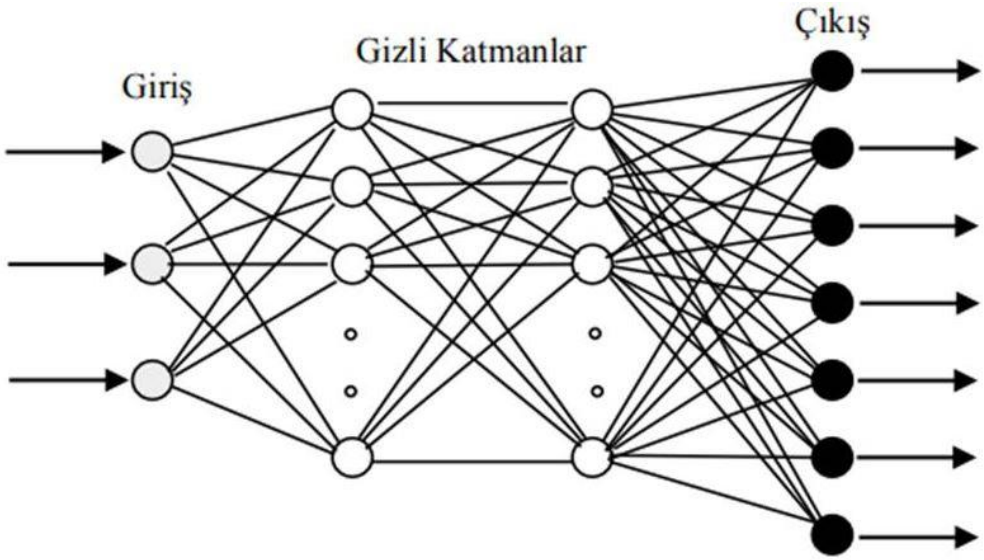

Şekil 3.18. Çok katmanlı yapay sinir ağlarının modeli (Gürsoy, 2018)

Şekil 3.18'de görüldüğü gibi, her bir nöron sinaptik ağırlıklarla bir önceki kısmın ilgili nöronlarına bağlanır. Bilgi genel olarak bağlantı ağırlıkları seti şeklinde saklanmaktadır. Bu durumun biyolojik sinir sistemlerinde sinaps etkinliğine karşılık geldiği düşünülmektedir. Modelde oluşturulan eğitim veri seti ile yapılan öğrenme, bağlantı ağırlıklarını uygun bir öğrenme modeli kullanarak düzenli bir duruma getirmeye çalışmaktadır. Ağın kullanıldığı öğrenme moduna göre; bir girdi istenen çıktı ile birlikte ağa sunar. Buna bağlı olarak da ilgili ağlar istenen çıktıyı üretmeye çalışacak şekilde ağırlık oranlarını ayarlar. Böylece eğitime başlamadan önce düzensiz ve anlamsız olan ağırlıklar, eğitimden sonra anlamlı bilgilere dönüşür (Kalogirou, 2001). Yapay sinir ağlarında kullanılan terimlerin biyolojik sinir ağlarında karşılık geldiği yapıyı gösteren terimler Çizelge 3.3'te verilmiştir.

Çizelge 3.3. Biyolojik sinir ağı ve yapay sinir ağlarının karşılaştırılması (Fausett, 1994)

Yapay Sinir Ağları (ANN)	Biyolojik Sinir Ağları
İşlemci Elemanı	Nöron
Nöronlar Arası Bağlantılar	Dentrit
Aktivasyon Fonksiyonu	Hücre Gövdesi
Yapay Nöron Çıkışı	Aksonlar
Ağırlıklar	Sinapslar

3.4.5.3. Yapay sinir ağını oluşturan birimler

Yapay sinir hücresi; girdiler, ağırlıklar, toplama fonksiyonu (birleştirme fonksiyonu), aktivasyon fonksiyonu ve çıktılar olmak üzere beş kısımdan oluşmaktadır (Çayıroğlu, 2015). Şekil 3.19'da temel yapay sinir ağları için bir model verilmiştir.

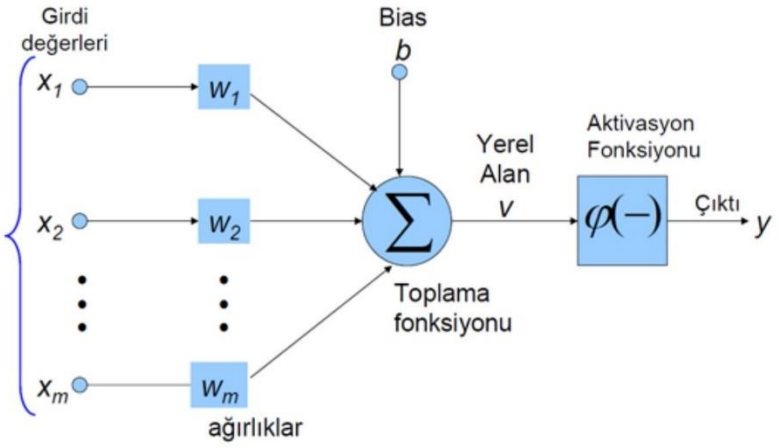

Şekil 3.19. Temel yapay sinir ağları modeli (Donuk, 2014)

Girdiler: Dış dünyadan bir yapay sinir hücresine gelen bilgiler ANN için girdi olarak tanımlanmaktadır. Aynı zamanda nöronlara kendinden önceki veya kendinden sonraki nörondan gelen bilgiler de YSA için girdi olarak tanımlanır (Öztemel, 2012).

Ağırlıklar: Yapay sinir hücresine gelen girdiler bir sonraki nörona geçerken önem derecesi oranında bir ağırlıkla çarpılır ve çekirdeğe iletilir. Böylece girdilerin, oluşacak olan çıktı ya da çıktıların üzerine olan etkileri belirlenir. Bu ağırlıklar için değerler pozitif, negatif veya sıfır olabilir. Herhangi bir ANN için negatif veya pozitif değerin ağa olan etkisi duruma göre farklılık gösterir. Ağırlığı sıfır olan girdilerin çıktı üzerinde bir etkisi bulunmamaktadır (Çayıroğlu, 2015).

Toplama fonksiyonu (Birleştirme Fonksiyonu): Toplama fonksiyonu hesaplanırken yapay sinir hücresine gelen girdi ile ağırlık değerinin çarpılmasıyla elde edilir. Bu işlemin sonucunda tüm girdilerin ağırlıklarla çarpılarak toplanmasıyla net girdiyi hesaplayan bir fonksiyondur. Birden fazla işlem biriminden veya dışarıdan gelen $x_1, x_2, x_3, \ldots x_m$ şeklindeki z adet giriş verisini alabilmektedir. Bu girişler, hücreye gelen w_1, w_2, ... w_m değerlerinin ağırlık oranlarına göre işlem biriminde etkili olmaktadır.

Hücreye gelen girişler ve ağırlıklar çarpıldıktan sonra b ile eşik değeri etki alanı belirlenir. Daha sonra kendisine gelen girdiler toplam fonksiyonu yardımıyla birleştirir. Sonuç olarak ANN'de toplam fonksiyonu verilen Eşitlik 3.20'deki gibi ifade edilir (Gürsoy, 2018)

$$y_x = \lceil \sum_{t=1}^{z} x_t w_t \rceil + b \qquad (3.20)$$

İşlem biriminin çıkışı, bir aktivasyon fonksiyonunun yardımıyla belirli bir davranışa yakınsamaktadır. Böylece hücresel davranış tanımlanmış olacaktır. Yapay işlem biriminin çıkış denkliği aşağıda Eşitlik 3.21'de verilmiştir (Gürsoy, 2018).

$$f_s = f(y_x) \qquad (3.21)$$

Aktivasyon Fonksiyonu: Bu fonksiyon sinir hücresine gelen net girdiyi işler. Bu işlemin sonucunda sinir hücresinin bu girdiye karşılık üreteceği çıktıyı belirleyen bir fonksiyon olarak tanımlanır. Aktivasyon fonksiyonunun genelde doğrusal olmayan fonksiyonlardan seçilmelidir. Aktivasyon fonksiyonun seçimi yapılırken türevinin kolay hesaplanabilir olması gerekmektedir. Günümüzde kullanımı yaygın olan "Çok katmanlı algılayıcı" modelinde genellikle "Sigmoid fonksiyonu" aktivasyon fonksiyonu olarak tercih edilmektedir (Çayıroğlu, 2015). Çizelge 3.4'te yaygın olarak kullanılan aktivasyon fonksiyonları görülmektedir.

Çizelge 3.4. ANN'de yaygın olarak kullanılan aktivasyon fonksiyonları

Aktivasyon fonksiyonu	Grafik	Fonksiyon Denklemi
Birim (step) Basamak fonksiyonu	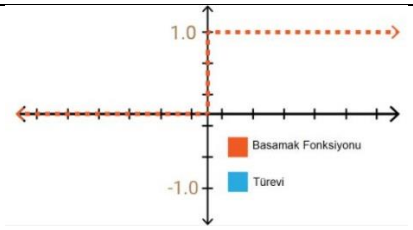	$f(x) = \begin{cases} I_x, & x \geq 0 \\ -1, & x < 0 \end{cases}$
Doğrusal (lineer) Fonksiyon	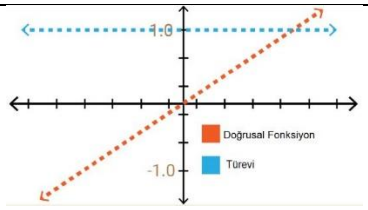	$f_{(x)} = n_x$
Sigmoid Fonksiyonu	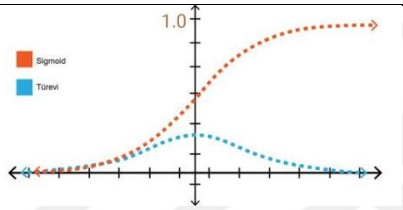	$f_{(x)} = \frac{1}{1 - e^{-x}}$
Hiperbolik Tanjant Fonksiyonu	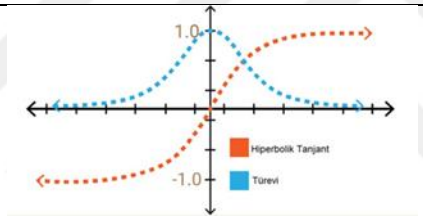	$f_{(x)} = \frac{e^{2x} - 1}{e^{2x} + 1}$

Çıktı: Yapay sinir ağlarında girdilere göre hesaplanan problemin çözümü çıktı olarak ifade edilir. Girdilerden her biri kendine ait olan ağırlık değeri ile çarpılarak fonksiyon oluşturulur. Daha sonra uygun olan birleştirme fonksiyonu kullanılarak net girdiye dönüştürülür. Bundan sonraki aşamada ise bulunan net girdi, aktivasyon fonksiyonu kullanılarak net çıktı olarak hesaplanarak sonuç elde edilir (Alan, 2013).

3.4.5.4. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağlarının, farklı özellik ve yapıları göz önüne alınarak sınıflandırması yapılabilir. ANN'ler yapılarına göre ve öğrenme yöntemlerine göre aşağıdaki gibi sınıflandırılabilirler.

3.4.5.4.1. Yapısal sınıflandırma

ANN için yapısal sınıflandırma, sinir hücrelerinin bağlantı yönlerine göre yapılmaktadır. Yapısal sınıflandırma, besleme durumuna göre ileri ve geri beslemeli ağ olarak sınıflandırılmaktadır.

3.4.5.4.1.1. İleri beslemeli ağ

İleri beslemeli bir ağ, yapısında ANN hücreleri genel olarak katmanlara ayrılarak oluşturulur. Giriş katmanında bulunan nöronlar, yapay sinir hücreleri vasıtası ile çıkış katmanına doğru tek yönlü bağlantılar oluşturularak iletilir. Genel olarak bir katmanda bulunan yapay sinir hücreleri bir önceki katmandaki yapay sinir hücreleri tarafından beslenmektedir (Sağıroğlu ve ark., 2003). Şekil 3.20'de yaygın olarak kullanılan ileri beslemeli ağ modeli görülmektedir.

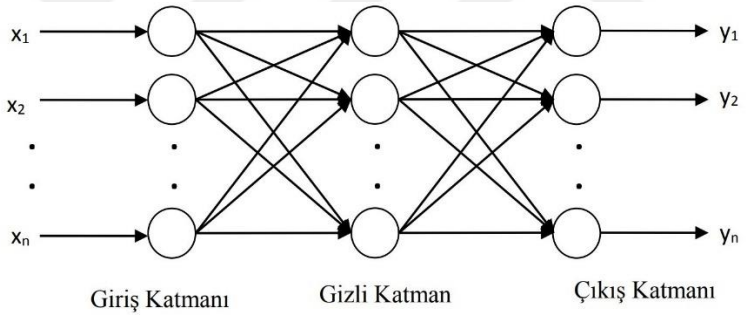

Şekil 3.20. İleri beslemeli ağ modeli (Gürsoy, 2018)

3.4.5.4.1.2. Geri beslemeli ağ

Geri beslemeli yapay sinir ağları, ara katman ve çıkış katmanlarındaki çıkışların, giriş birimlerine ya da bir önceki katmana doğru (ara katmanlara) geri beslendiği bir ağ yapısı olarak tanımlanmaktadır. İleri besleme ağ mimarisinden farklı olarak; girişler hem ileri, hem geri yönde aktarılmaktadır (Güven, 2005). Geriye beslemeli ağların dinamik hafızaları bulunmaktadır. Bir katmandan diğer bir katmana gelen çıkış hem o anki girişleri hem de önceki girişleri yansıtmaktadır. Bundan dolayı, geri beslemeli sinir ağları çoğunlukla tahmin amaçlı uygulamalar için kullanılmaktadırlar ve bu ağlar mimarisi zaman serilerinin tahmininde de oldukça başarı sağlayan bir ağ yapısı olarak

bilinirler. Geri beslemeli ağlara Hopfield, Elman, Jordan, Narmax gibi ağlar örnek verilebilir (Sağıroğlu ve ark., 2003). Şekil 3.21'de geri beslemeli bir ağ modeli gösterilmektedir.

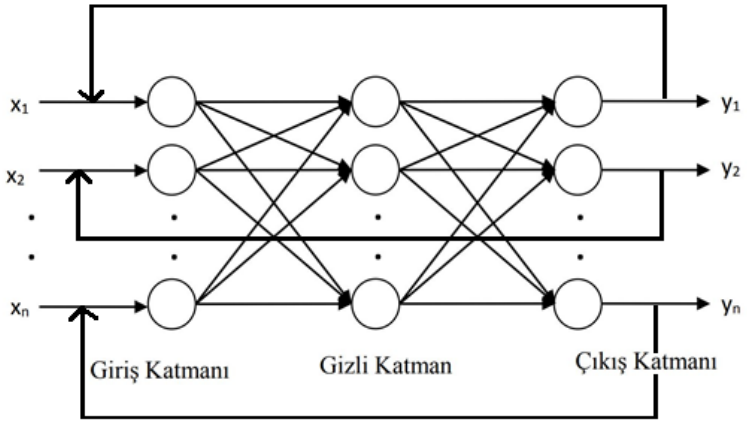

Şekil 3.21. Geri beslemeli ağ modeli (Gürsoy, 2018)

3.4.5.4.2. Öğrenme yöntemlerine göre sınıflandırma

ANN'ler de öğrenme, eğitim ve gözlem sonucunda oluşan davranış değişiklikleri, kurallar ve yöntemler yardımıyla ağırlıkların güncellenmesi ile sağlanabilir. Öğrenme algoritması, problemin özelliğine göre kuralların ANN'ye nasıl uygulanacağını belirtir (Güven, 2005).

3.4.5.4.2.1. Danışmanlı öğrenme yöntemi

Danışmanlı öğrenme yönteminde, çözülecek problemlerin yapılarına ve davranışlarına göre önceden hazırlanan eğitim seti kullanılmaktadır. ANN modeli kullanılarak üretilen çıkış değerleri ile gerçek değerler karşılaştırılarak hata oranı tespit edilir. Rastgele atanan ağırlık değerleri hata payını düşürmek için tekrar hesaplanarak düzenlenmektedir. Ağırlık parametre değerleri, hata payı kabul edilebilir seviyeye gelinceye kadar bu işlem tekrar etmektedir. Rumelhart ve McClelland, Widrow ve Hoff tarafından geliştirilen geri beslemeli ağlar ve delta kuralları öğretmeli öğrenmeye örnek olarak verilebilir (Rumelhart ve McClelland, 1989; Widrow ve Hoff, 1960).

3.4.5.4.2.2. Danışmansız öğrenme yöntemi

Bu yöntem, çözülecek probleme ait giriş verilerine karşılık giriş bilgilerine bağlı olarak öğrenmeyi gerçekleştiren bir yöntemdir. Kurulan ağ öğrenme kurallarını, giriş bilgilerine göre geliştirecek şekilde bir algoritma barındırır. Böylece giriş verileri gruplandırılarak eğitildikten sonra verilen girişlerin hangi sınıfa ait oldukları belirlenir. Kohonen tarafından geliştirilen SOM öğrenme yöntemi danışmansız öğrenme yöntemi olarak tanımlanır (Kohonen, 1972; Kohonen, 2012).

Bu tez çalışmasında, alınan hava durumu (sıcaklık, hissedilen sıcaklık, basınç ve nem değerleri) verileri ve deneysel olarak radardan alınan mesafe verileri kullanılmıştır. Girdi olarak sıcaklık, hissedilen sıcaklık, basınç ve nem verilileri kullanılmıştır. Ölçüm yapılan mesafe sabit olduğundan dolayı ölçüm yapılan radar mesafe verisinden sabit olan gerçek mesafe verisi çıkartılarak radar mesafe hata verisi elde edilmiştir. Hesaplanan radar hata verisi tüm modellerde çıktı olarak kullanılarak farklı hava koşulları için radar mesafe verisinde oluşan hata hesaplamaları yapılmıştır. Çalışmada 11223 adet veri içeren bir set oluşturulmuştur. Gerek Accuweather üzerinden alınan hava durumu verileri gerekse radar üzerinden alınana mesafe verileri %70'i eğitim ve geriye kalan %30'u ise test verisi olacak şekilde bölünerek kullanılmıştır. Böylece kullanılan tüm yöntemler için tahmin hesaplamaları yapılarak radar mesafe ölçüm verisi için en iyi tahmin yöntemi belirlenmiştir.

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu çalışmada veri seti oluşturulduktan sonra veri tabanı üzerinden veriler alınarak MLR, SVM, ANFIS, KNN ve ANN tahmin yöntemleri kullanılarak radar hata mesafeleri tahmin edilmiştir. Çalışmada girdi olarak sıcaklık, hissedilen sıcaklık, nem ve basınç değerleri kullanılmıştır. Radar ile ölçümü yapılan mesafe verisi sabit olmasından dolayı ölçülen mesafeden hedefin gerçek mesafesi çıkartılarak radar mesafe hatası verisi oluşturulmuştur. Çalışmada kullanılan her yöntem için Şekil 4.1'de görülen ana model kullanılmıştır.

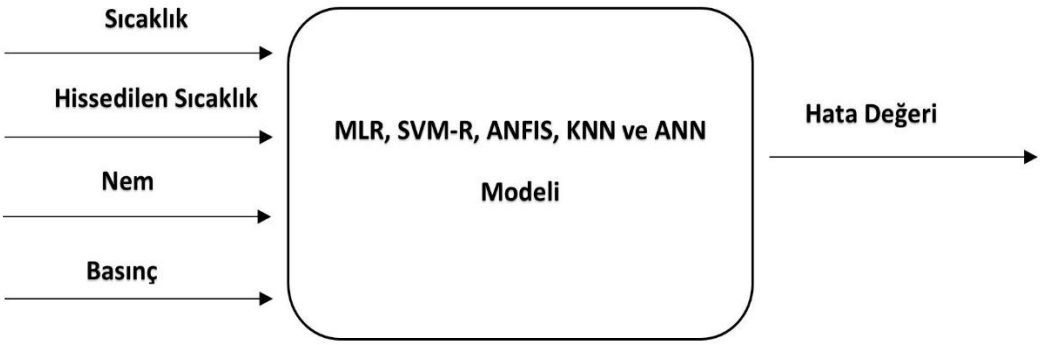

Şekil 4.1. Radar mesafe ölçüm hata verisi tahmini için kullanılan model

Kullanılan tüm yöntemlerde sıcaklık, hissedilen sıcaklık, nem ve basınç değerlerine göre radar mesafe hata verisinin tahmin edilmesine çalışılmıştır. Kullanılan yöntemlerin tamamında veri setinin 7900 adedi eğitim ve 3323 adedi ise test verisi olarak kullanılmıştır.

4.1. Değerlendirme Kriterleri

Sonuçlar değerlendirilirken MAE, MAPE, MSE ve RMSE sonuçlarına göre modellerin doğruluk oranları analiz edilmiştir.

4.1.1. Ortalama mutlak hata (Mean Absolute Error, MAE)

MAE değeri, iki sürekli değişken arasındaki farkın bir ölçüsüdür. MAE, her gerçek değer ile verilere en iyi uyan çizgi arasındaki ortalama dikey mesafedir. MAE

ayrıca her bir veri noktası ile en uygun çizgi arasındaki ortalama yatay mesafeyi temsil etmektedir. MAE değeri kolayca yorumlanabilir olduğundan regresyon ve zaman serisi problemlerinde sıklıkla kullanılır. MAE, bir dizi tahmindeki ortalama hata sayısını, yönlerini dikkate almadan ölçen ve tüm bireysel hataların ortalamaya eşit olarak ağırlıklandırıldığı doğrusal bir puandır. MAE değeri 0 ile ∞ arasında değişebilir. MAE değeri Eşitlik 4.1 ile hesaplanmaktadır (Chicco ve ark., 2021).

$$MAE = \frac{1}{n}\sum_{i=1}^{n} |Tahmin_i - Gerçek_i| \qquad (4.1)$$

4.1.2. Ortalama mutlak yüzde hata (Mean Absolute Percentage Error, MAPE)

Regresyon ve zaman serileri modellerinde tahminlerin doğruluk oranlarını ölçmek için MAPE sıklıkla kullanılmaktadır. Gerçek değerler arasında sıfır içeren değerler varsa, sıfır ile bölünme olacağından MAPE değeri hesaplanamaz. Çok düşük tahmin değerleri için hesaplandığında yüzde hatası %100'ü geçemez. Fakat çok yüksek tahmin değerleri için yüzde hatasının bir üst sınırı yoktur. MAPE, tahmin modellerinin doğruluğunu karşılaştırmak için kullanıldığında, tahminleri çok düşük olan bir yöntemi sistematik olarak seçmesi nedeniyle önyargılıdır. Bu problem, tahmin değerleri için gerçek değerlerine oranını bulan bir doğruluk ölçütü kullanılarak çözülebilir. Bu yaklaşım geometrik ortalama açısından yorumlanabilen tahminlere neden olur. Eşitlik 4.2'de MAPE'nin hesaplanması için kullanılan denklem görülmektedir (Chicco ve ark., 2021).

$$MAPE = (1/N)\sum_{i=1}^{N} \left|\frac{Tahmin_i - Gerçek_i}{Gerçek_i} \times 100\right| \qquad (4.2)$$

4.1.3. Ortalama kare hata (Mean Squared Error, MSE)

MSE, bir regresyon eğrisinin bir dizi noktaya ne kadar yakın olduğunu ifade eden bir sayısal değerdir. MSE, bir makine öğrenmesi için tahminleyicinin performansını ölçmektedir. MSE her zaman pozitif değer alır. MSE değeri sıfıra yakın olan tahmin algoritma yada modellerin çok daha iyi bir performans gösterdiği şeklinde yorumlanabilir. MSE Eşitlik 4.3 ile hesaplanır (Chicco ve ark., 2021).

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(Tahmin_i - Gerçek_i)^2 \quad (4.3)$$

4.1.4. Kök ortalama kare hata (Root mean square error, RMSE)

Bir makine öğrenmesi modeli için, tahminleyicinin tahmin ettiği değerler ile gerçek değerleri arasındaki uzaklığın bulunmasında sıklıkla kullanılan bir ölçüttür. RMSE hatanın büyüklüğünü ölçen kuadratik bir büyüklüktür. RMSE, tahmin hatalarının standart sapmasıdır. Başka bir deyişle RMSE, verilere en iyi uyan çizgi etrafında o verilerin ne kadar yoğun olduğunu ifade eder. RMSE değeri 0'dan ∞'a kadar farklı değerler alabilir. RMSE değerinin sıfır olarak hesaplanmış olması modelin hiç hata yapmadığını gösterir. RMSE değeri Eşitlik 4.4 ve 4.5'te gösterildiği şekilde hesaplanmaktadır (Chicco ve ark., 2021).

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N} R^2}{N}} \quad (4.4)$$

$$R^2 = (Tahmin_i - Gerçek_i)^2 \quad (4.5)$$

4.2. Verilerin Analizi ve Dağılımı

Radar ile yapılan mesafe ölçüm değerleri ve ölçüm anında alınan hava durumu verileri veri tabanına kaydedilmiştir. Ölçümler farklı günlerde alınmış ve toplam 11223 veriden oluşmaktadır. Bu veriler analiz için veri tabanından alınmıştır. Sabit konumlu hedefin radara olan mesafesi (5440m) bilindiği için ölçülen radar mesafe değerlerinden gerçek değer çıkarılarak radar mesafe hata verisi elde edilmiştir.

MLR, SVM, ANFIS, KNN ve ANN modelleri ayrı ayrı kullanılarak hata değerlerinin hava durumu verileriyle ilişkilendirilmesi sağlanmıştır. MLR, SVM, ANFIS, KNN ve ANN modelleri için sıcaklık, hissedilen sıcaklık, nem ve basınç değerleri girdi, hesaplanan radar mesafe hata verisi ise çıktı olarak modellerde kullanılmıştır. Çizelge 4.1'de girdi ve çıktı için kullanılan verilerin dağılımları ve istatiksel parametreleri görülmektedir.

Çizelge 4.1. Deney setinden elde edilen verilerin dağılımları ve istatistik parametreleri

Parametreler	Birim	Ortalama	S.Sapma	Min.	Mak.	Çarpıklık	Basıklık
Sıcaklık	ºC	7.7	12.44	-14	34.71	0.557	-1.02
H. Sıcaklık	ºC	3.23	14.99	-19.33	32.29	0.483	-1.22
Nem	%	61.3	22.9	12	100	-0.517	-0.79
Basınç	hPa	1012.4	7.53	996	1029	0.3490	-0.15
Radar Hatası	m	16.6	4.99	3	30	-0.329	-0.72

Şekil 4.2'de çalışma boyunca oluşturulan 11223 adet veri için kayıt altına alınan sıcaklık değerleri görülmektedir. Bu grafiğe bakıldığında -15 ºC 'den 38 ºC'ye kadar olan geniş bir aralıkta sıcaklık değerlerinin kayıt altına alındığı görülmektedir.

Şekil 4.3'te çalışma boyunca oluşturulan 11223 adet veri için kayıt altına alınan hissedilen sıcaklık değerleri görülmektedir. Bu grafiğe bakıldığında -20 ºC 'tan 35 ºC kadar olan geniş bir aralıkta hissedilen sıcaklık değerlerinin kayıt altına alındığı görülmektedir.

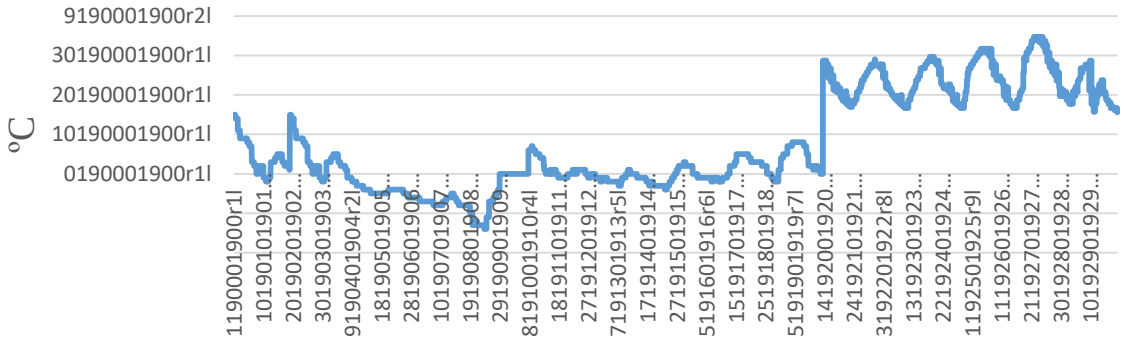

Şekil 4.2. Çalışma boyunca kaydedilen sıcaklık değerlerinin grafiği

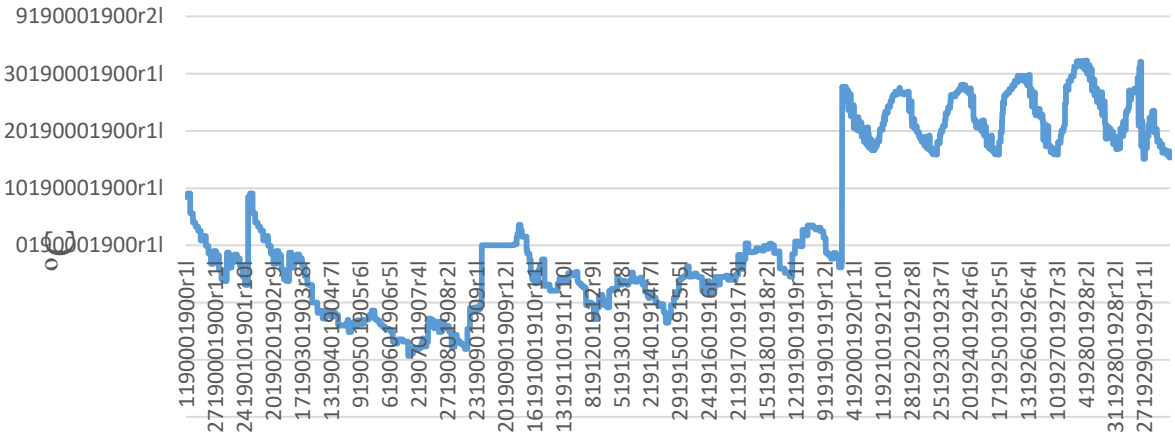

Şekil 4.3. Çalışma boyunca kaydedilen hissedilen sıcaklık değerlerinin grafiği

Şekil 4.4’te kayıt altına alınan basınç değerleri görülmektedir. Bu grafiğe bakıldığında 995 hpa’dan 1030 hpa’ya kadar bir aralıkta basınç değerlerinin kayıt altına alındığı görülmektedir.

Şekil 4.5’te kayıt altına alınan nem değerleri görülmektedir. Bu grafiğe bakıldığında %20 den %100’e kadar olan geniş bir aralıkta nem değerlerinin kayıt altına alındığı görülmektedir.

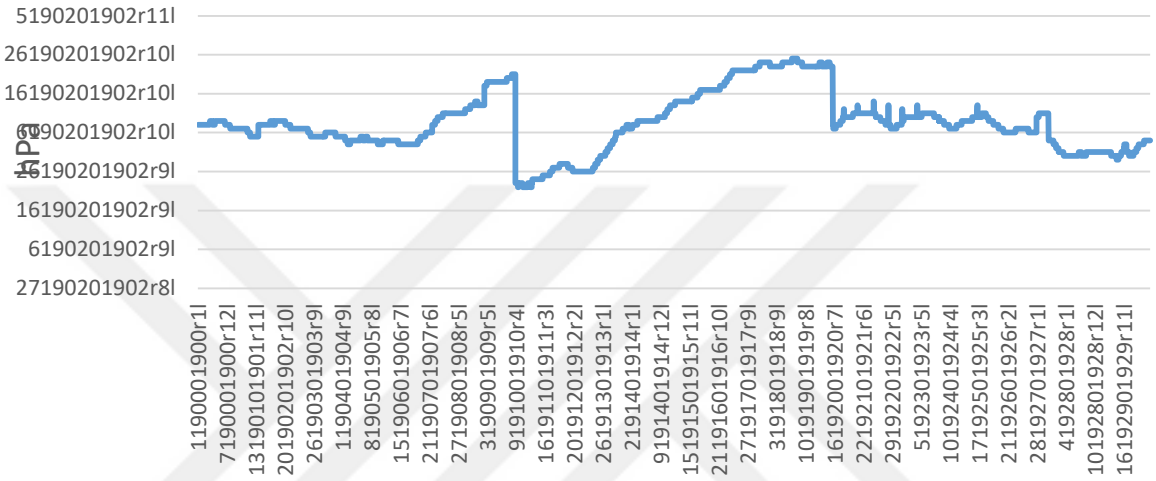

Şekil 4.4. Çalışma boyunca kaydedilen basınç değerlerinin grafiği

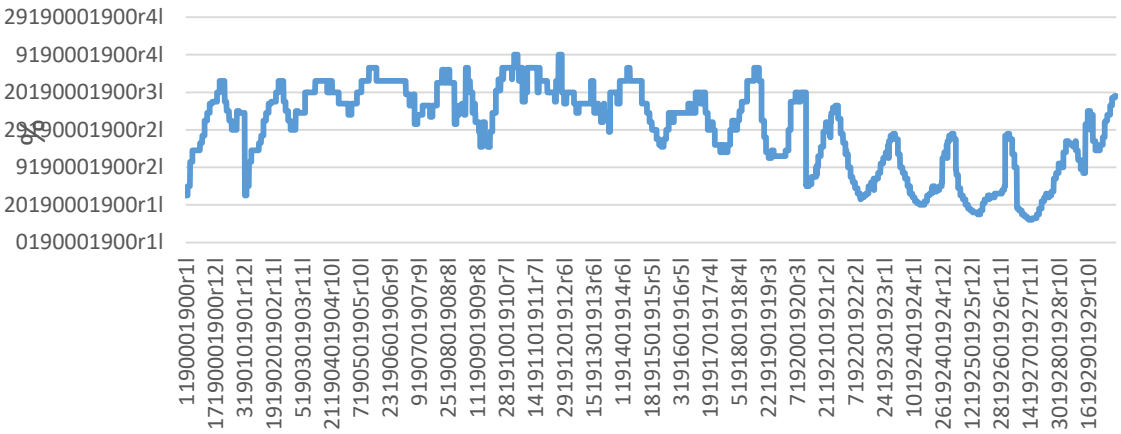

Şekil 4.5. Çalışma boyunca kaydedilen nem değerlerinin grafiği

4.2.1. SVM-R yönteminin sonuçları

SVM-R yöntemi sonucunda elde edilen verilerin istatistiksel sonuçları Çizelge 4.2'de gösterilmiştir. SVM-R yöntemi %29.66 (MAPE) ile radar mesafe hatasını tahmin edilebilmiştir.

Çizelge 4.2. SVM modeli kullanılarak elde edilen istatistiksel sonuçlar

Parametre	MAE	MAPE (%)	RMSE	MSE
SVM-R	3.672749103	29.66	4.746418132	22.52848508

Elde edilen MAPE değerinin yüksek olduğu ve dolayısıyla SVM-R yöntemiyle yapılacak tahminlerin bu çalışmada yüksek doğrulukta olmayacağı görülmektedir. Şekil 4.6'da SVM-R modeli ile elde edilen ve gerçek hata değeri aynı grafik üzerinde gösterilmiştir.

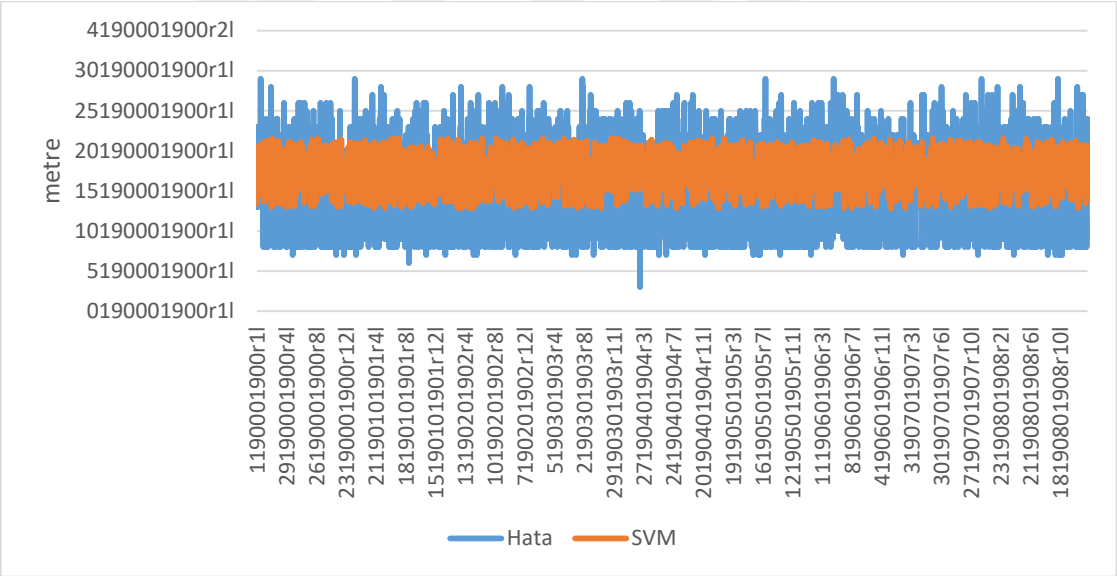

Şekil 4.6. SVM-R ile tahmin edilen hata değeri ve gerçek hata değerleri

Şekil 4.6'da verilen grafikte de SVM ile yapılan tahminlerin gerçek hata değerlerinden büyük oranda uzak olduğu görülmektedir.

4.2.2. MLR yönteminin sonuçları

Çoklu doğrusal regresyon metodu ile yapılan hesaplamalarda elde edilen tüm giriş değerleri için hesaplanan istatistiksel değerler Çizelge 4.3'te verilmiştir.

Çizelge 4.3. MLR modelinin tüm giriş değerleri için hesaplanan istatistiksel değerler

Parametre	Katsayılar	D değeri	T değeri	p değeri
Sabit	-325.152091	9.096058892	-35.7464804	1.5853E-259
Sıcaklık	0.82224653	0.045305615	18.14888	3.78435E-72
H. Sıcaklık	-0.50470213	0.033054261	-15.2688979	6.76302E-52
Nem	0.085879182	0.005764657	14.89753542	1.60298E-49
Basınç	0.327737518	0.008641051	37.92797123	2.5123E-289

T değeri, alternatif hipoteze karşı boş hipotezi ifade etmek için kullanılabilir. p değeri, bir hipotez testinde istatistiksel anlamlılığı belirlemek için kullanılır.

Eşitlik 4.6'da verilen denklem MLR yöntemi ile radar mesafe hata değerini elde etmek için oluşturulmuştur.

$$\text{Hata}=-325.15+0.82\times\text{Sıcaklık}-0.50\times\text{H.Sıcaklık}+0.08\times\text{Nem}+0.32\times\text{Basınç} \quad (4.6)$$

MLR kullanılarak yapılan radar hata tahminleri için istatistiksel sonuçlar Çizelge 4.4'te görülmektedir.

Çizelge 4.4. MLR modeli kullanılarak elde edilen istatiksel sonuçlar

Parametre	MAE	MAPE (%)	RMSE	MSE
MLR	4.46	34.52	5.44	29.61

Sonuçlar analiz edildiğinde, özellikle %34.52 MAPE değeri için, değerin yüksek olduğu görülmektedir (hatta SVM modeline kıyasla daha yüksek). Gerçek hata değerleri ile MLR yöntemi ile hesaplanan hata değerleri aynı grafikte Şekil 4.7'de gösterilmektedir.

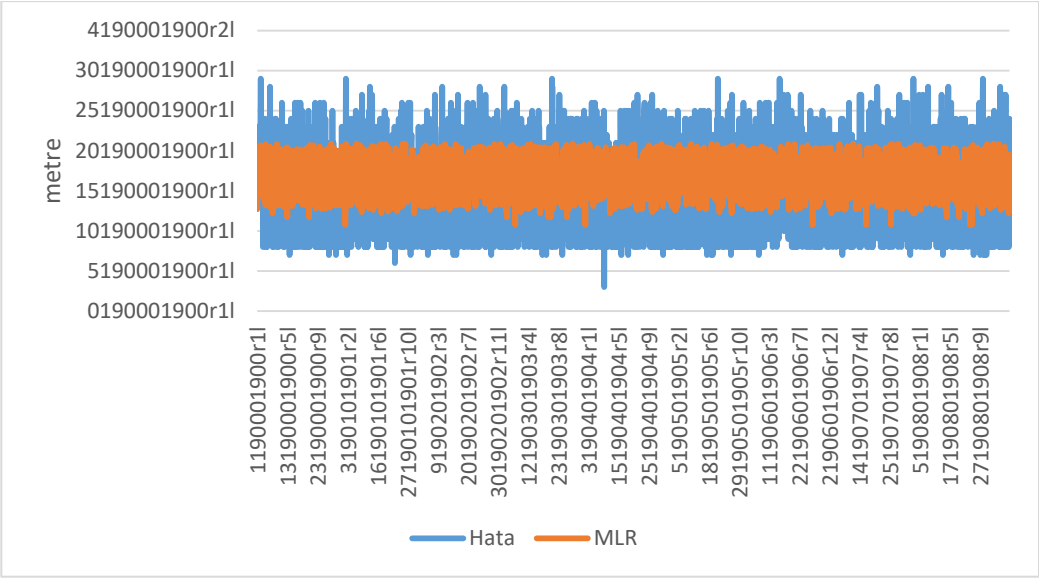

Şekil 4.7. MLR ile tahmin edilen hata değerleri ve gerçek hata değerleri

Şekil 4.7 incelendiğinde SVM modeline yakın bir oranda hata değerlerinin tahmin edilebildiği görülmektedir. Bu yüzden MLR yönteminin de SVM gibi hata tahmininde yüksek doğruluğa ulaşmakta zayıf kaldığı görülmektedir.

4.2.3. ANFIS yönteminin sonuçları

ANFIS için, modeldeki her giriş verisi için dört üyelik fonksiyonu kullanılarak eğitim yöntemi ile toplamda $4^4 = 256$ kurallık bir model oluşturulmuştur. Üyelik fonksiyonları Gaussian olarak seçilmiştir. Sugeno Bulanık Çıkarım Sistemi kullanılmıştır. ANFIS yöntemindeki hata değerini olabildiğince yakın tahmin edebilmek için veri seti RMSE değerinde herhangi bir değişiklik olmayana kadar çalıştırılmıştır. RMSE değeri ne kadar küçük olursa, modelin tahmini o kadar doğru olur, bu nedenle veriler RMSE değerindeki değişiklik doğrusal olana kadar eğitilmeye devam edilmiştir. Böylece hatanın gerçek değere en yakın olacağı durumun hesaplanmasına olanak sağlayacak bir yöntem elde edilmiştir. Çizelge 4.5'te ANFIS modeli ile elde edilen istatistiksel sonuçlar görülmektedir.

Çizelge 4.5. ANFIS modeli kullanılarak elde edilen istatiksel sonuçlar

Parametre	MAE	MAPE (%)	RMSE	MSE
ANFIS	2.344970123	17.35077355	3.2941362	10.85133328

Çizelge 4.5 incelendiğinde ANFIS modelinin istatistiksel sonuçları hem MLR hem de SVM modellerine göre daha iyi bir doğruluk ile tahmin yapabildiği görülmektedir. Özellikle MAPE değeri incelendiğinde yaklaşık %17.35'lik bir hata ile ANFIS modelinde radar mesafe hataları tahmin edilebilmektedir. Oran her ne kadar diğer modellere göre daha doğru sonuçlar elde edildiğini gösterse de hata oranının yine büyük olduğu değerlendirilmiştir.

Şekil 4.8'de ANFIS ile tahmin edilen hata değerleri ve gerçek hata değerleri aynı grafik üzerinde gösterilmiştir. MLR ve SVM grafikleri göz önünde bulundurulduğunda hatanın ANFIS yönteminde daha az olduğu açıkça görülmektedir.

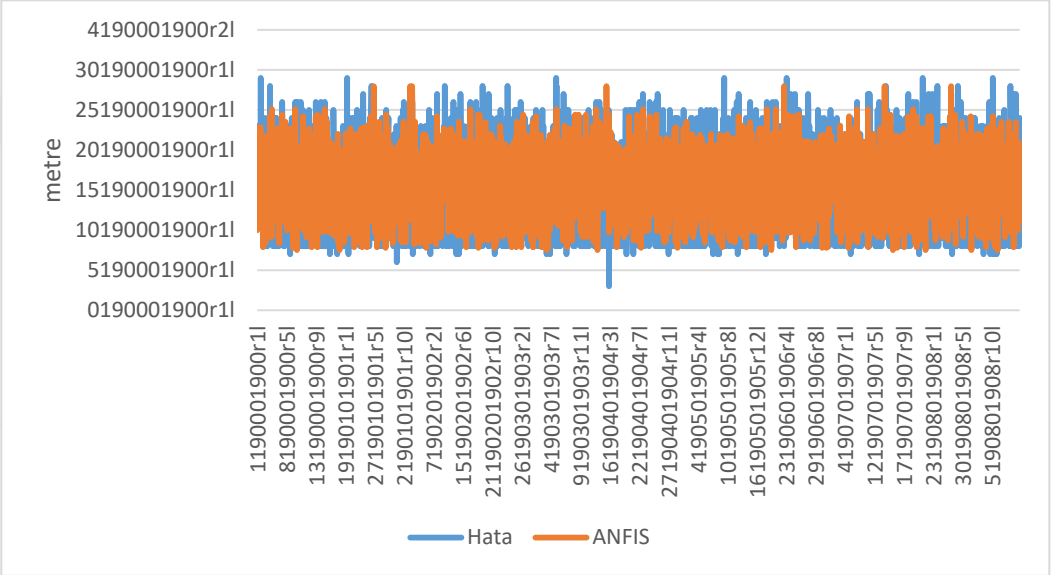

Şekil 4.8. ANFIS ile tahmin edilen hata değeri ve gerçek hata değerleri

4.2.4. KNN yönteminin sonuçları

KNN modeli için C# programlama dili ile komşuluk oranlarına dayalı tahminler yapabilen bir algoritma geliştirilmiştir. Bu algoritma ile en yakın komşu adedi olarak 7, 9, 11 ve 13 değerlerine göre tahminler yapılmıştır. Çizelge 4.6'da KNN modelinde farklı K değerlerine göre elde edilen istatistiksel değerler verilmiştir.

Çizelge 4.6. KNN modeli kullanılarak 7, 9, 11 ve 13 komşuluklarına göre elde edilen istatiksel sonuçlar

Parametre	MSE	RMSE	MAE	MAPE (%)
KNN7	4.933795	2.221215	1.22570	7.803
KNN9	4.678303	2.162938	1.151369	7.37
KNN11	5.445983	2.333663	1.262413	7.97
KNN13	5.157087	2.270922	1.247367	7.90

Çizelge 4.6 incelendiğinde farklı K komşuluk değerlerine göre farklı sonuçlar elde edilmiştir. K değeri 7'den 9'a artırıldığında MAPE değerinin düştüğü görülse de 9. komşuluktan sonra K= 11 ve K= 13 için MAPE değerlerinin yükseldiği görülmektedir. 9. komşuluk değerinde (KNN_9) MAPE değeri %7.37 ile en iyi sonucu elde ederken, 11. komşuluk için %7.97, 13. komşuluk için ise %7.9 olarak hesaplanmıştır. Dolayısı ile KNN yöntemi için 9. komşuluk değeri referans alınmıştır. Şekil 4.9'da KNN9 ile tahmin edilen hata değerleri ve gerçek hata değerleri aynı grafik üzerinde gösterilmiştir.

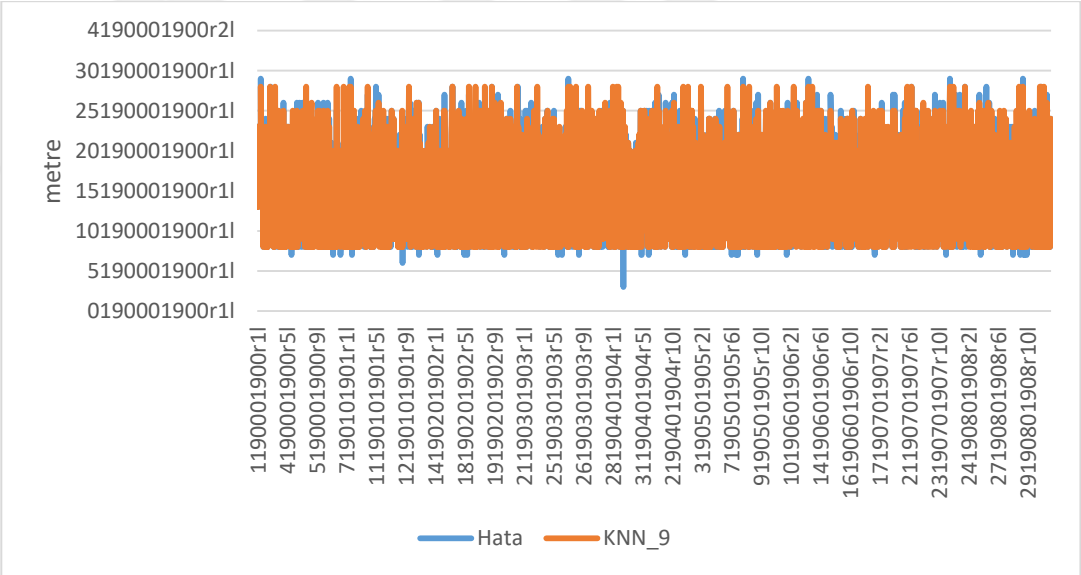

Şekil 4.9. KNN9 ile tahmin edilen hata değeri ve gerçek hata değerleri

4.2.5. ANN yönteminin sonuçları

ANN modeli için 10 ağ kullanan ve 10 katmanlı bir model oluşturulmuştur. ANN yöntemi sonucunda elde edilen istatistiksel sonuçlar Çizelge 4.7'de gösterilmiştir.

Çizelge 4.7. ANN modeli kullanılarak elde edilen istatiksel sonuçlar

Parametre	MAE	MAPE (%)	RMSE	MSE
ANN	1.061064115	7.15	1.6770636	2.812542333

Çizelge 4.7 incelendiğinde az bir farkla da olsa en iyi MAPE değerinin (%7.15) ANN yöntemi ile elde edildiği gözlenmiştir.

Şekil 4.10'da gerçek hata ve ANN ile tahmin edilen değerler aynı grafikte görülmektedir. Değerler incelendiğinde gerçek değerlere çok yakın tahminlerin ANN modeli ile gerçekleştiği görülmektedir. Çalışma boyunca kullanılan 5 yöntem kıyaslandığında en doğru sonucun ANN modeli ile tahmin edilebildiği açıkça görülmüştür.

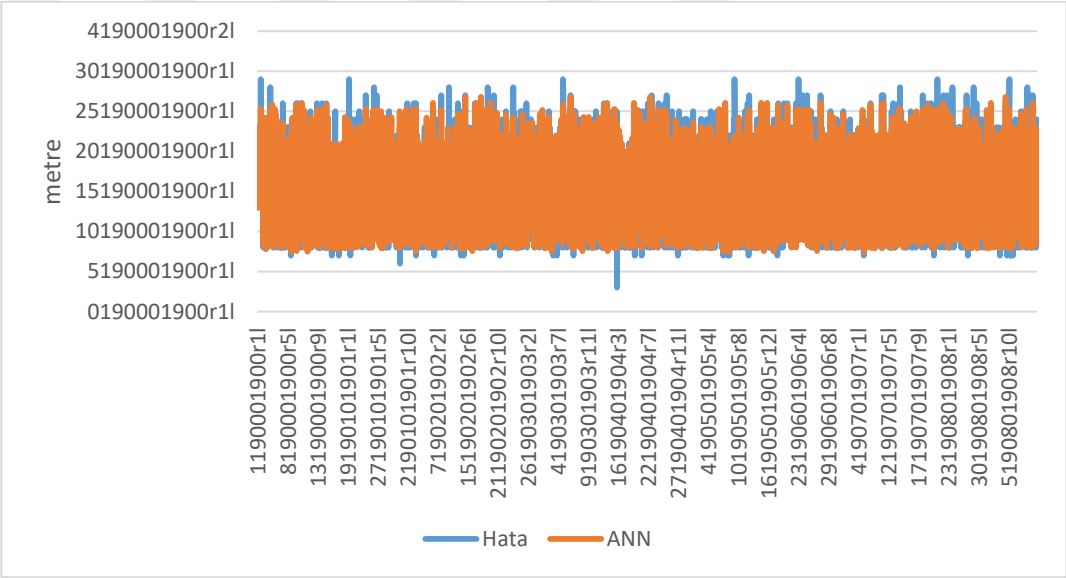

Şekil 4.10. ANN ile tahmin edilen hata değeri ve gerçek hata değerleri

4.3. MLR, SVM, ANFIS, KNN ve ANN Yöntemlerinin Karşılaştırılması

Yapılan çalışmada sonuçların daha açık gösterilebilmesi için 5 yöntem ile yapılan tahminlerin ve gerçek hata verilerinin rastgele seçilen 50 adet veri için gösterimi aynı grafik üzerinde Şekil 4.11'de birleştirilmiştir.

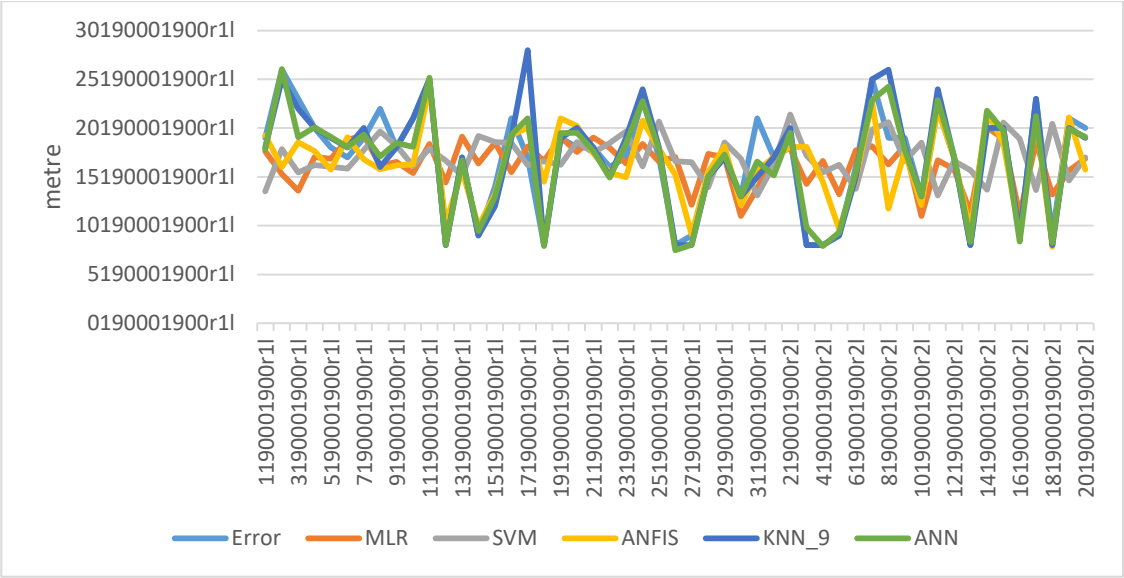

Şekil 4.11. Rastgele seçilen 50 verinin MLR, SVM, ANFIS, KNN, ANN modelleri ile tahmin edilen sonuçları ve gerçek hata verilerinin karşılaştırılması

50 veri için her model ile yapılan tahminlerin gerçek hata verisi ile beraber verilmiş hali Şekil 4.12, Şekil 4.13, Şekil 4.14, Şekil 4.15 ve Şekil 4.16'da verilmiştir.

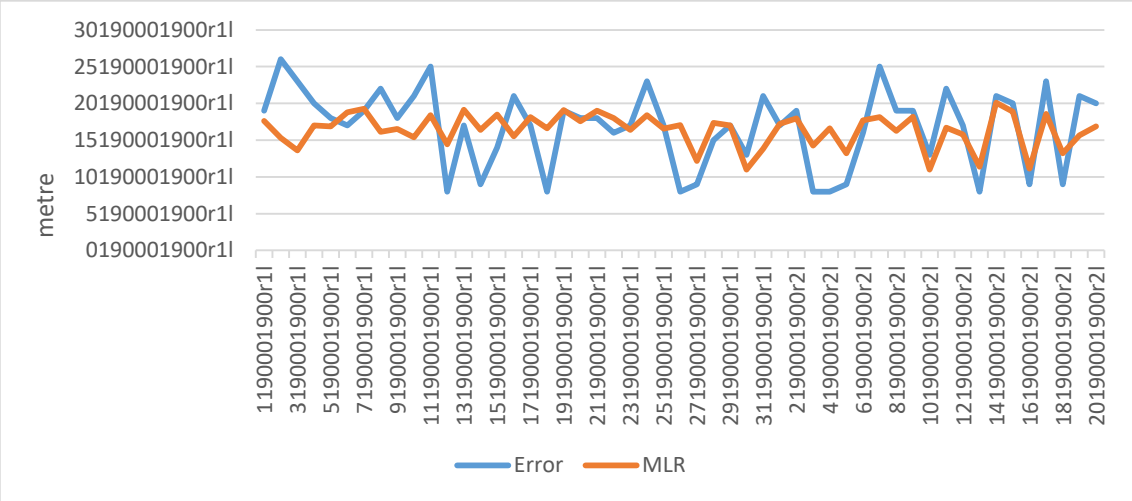

Şekil 4.12. Rastgele seçilen 50 verinin MLR modeli ile tahmin edilen sonuçlarının ve gerçek hata verilerinin karşılaştırılması

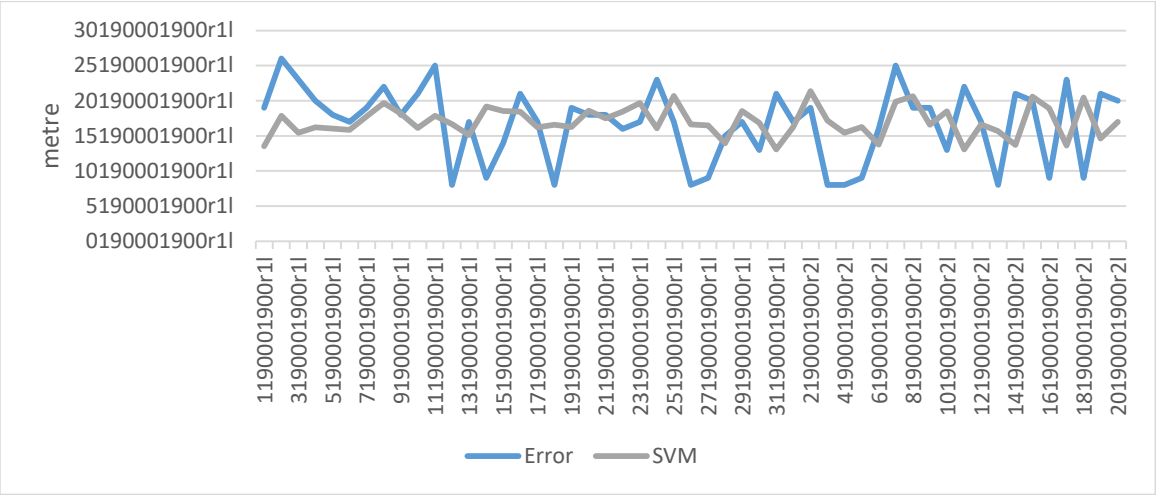

Şekil 4.13. Rastgele seçilen 50 verinin SVM modeli ile tahmin edilen sonuçları ve gerçek hata verilerinin karşılaştırılması

MLR ve SVM yöntemleri doğrusal regresyon yapmalarından dolayı karmaşık olan bu problemde sonuçların istenen oranlarda çıkmadığı görülmüştür.

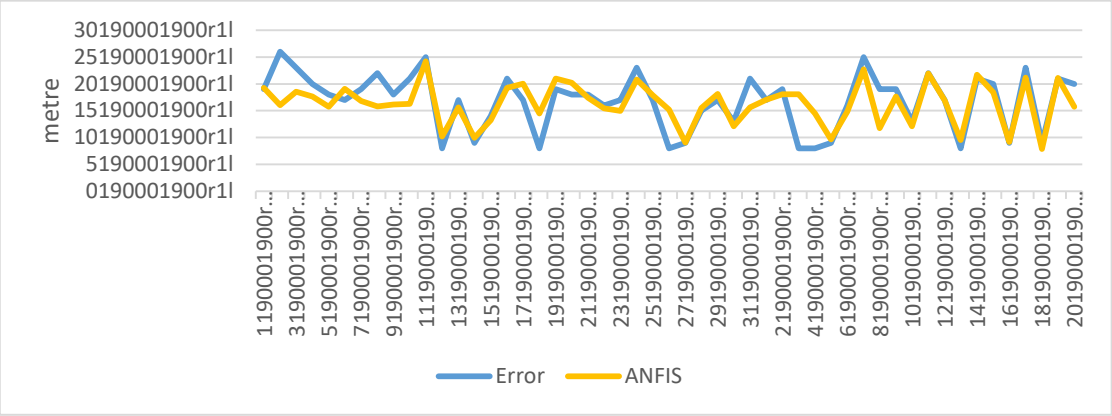

Şekil 4.14. Rastgele seçilen 50 verinin ANFIS modeli ile tahmin edilen sonuçları ve gerçek hata verilerinin karşılaştırılması

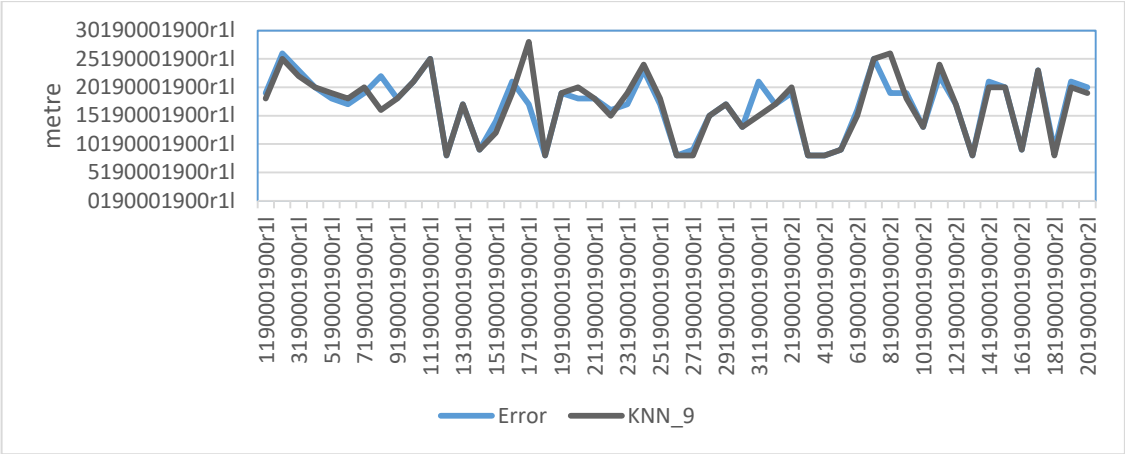

Şekil 4.15. Rastgele seçilen 50 verinin KNN modeli ile tahmin edilen sonuçları ve gerçek hata verilerinin karşılaştırılması

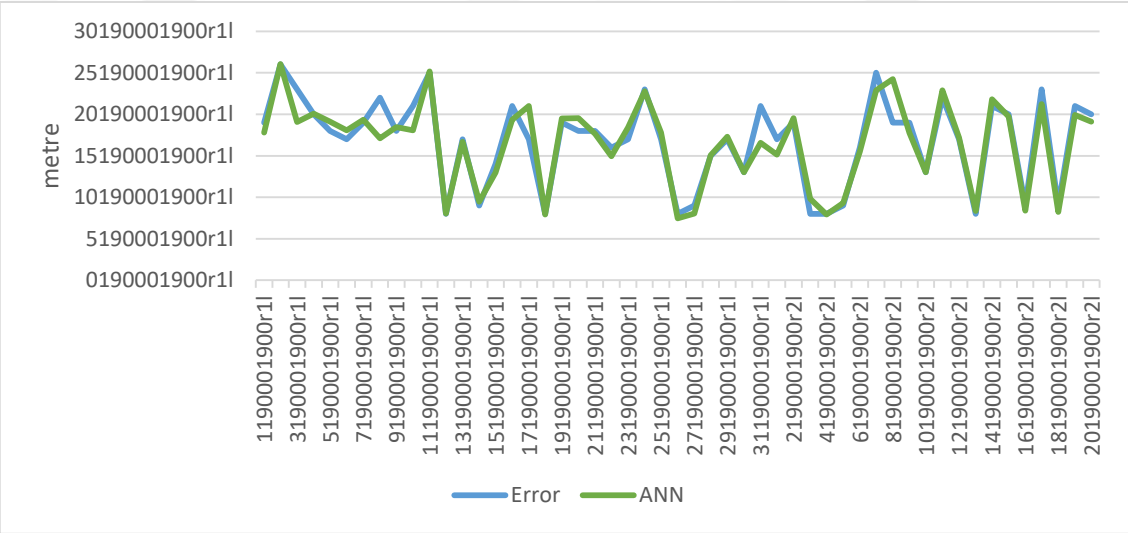

Şekil 4.16. Rastgele seçilen 50 verinin ANN modeli ile tahmin edilen sonuçları ve gerçek hata verilerinin karşılaştırılması

Şekiller incelendiğinde ANN yöntemi ile tahmin edilen değerlerin en büyük doğruluk ile gerçekleştirildiği görülmektedir.

Tüm yöntemler için elde edilen istatistiki sonuçlar Çizelge 4.8'de toplanmıştır.

Çizelge 4.8. MLR, SVM, ANFIS, KNN ve ANN modellerinin istatistiksel sonuçları

Parametre	MAE	MAPE (%)	MSE	RMSE
SVM	3.672749103	29.66	22.52848509	4.74641813
MLR	4.461970211	34.52	29.61248315	5.441735307
ANFIS	2.344970123	17.35	10.85133328	3.2941362
KNN_9	1.151369245	7.37	4.678302738	2.16293845
ANN	1.061064115	7.15	2.812542333	1.6770636

Özetlenecek olursa; MLR, SVM, ANFIS, KNN ve ANN modelleri için istatistiksel hesaplamalar yapılmış ve sonuçlar ortaya konmuştur. Çizelge 4.8 ve Şekil 4.11 incelendiğinde doğrusal tahmin yöntemleri olan MLR ve SVM modellerinin diğer yapay zeka yöntemleri kullanılarak tahmin yapan ANFIS, KNN ve ANN yöntemlerine göre başarı oranının çok daha düşük olduğu görülmektedir. Yapay zekâ yöntemlerinin çok daha karmaşık problemleri çözmede daha üstün özellikleri olmasından dolayı daha başarılı sonuçlar ortaya çıkmaktadır. Bu çalışmada ortaya koyulan problem için yapılan uygulamada yapay zekâ yöntemleri kendi aralarında kıyas yapıldığında ise ANFIS modelinin diğer modellerden daha zayıf sonuçlar ortaya koyduğu görülmüştür. Yapılan hesaplamalar sonucunda ANN yönteminin diğer tüm yöntemlere göre çok daha doğru tahminler yaptığı açıkça görülmektedir.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Günümüzde radar ile yapılan mesafe ölçümlerinin doğruluğu hassas uygulamalar için büyük önem taşımaktadır. Özellikle savunma sanayi ve otonom araçlar gibi bazı sektörlerde bunun önemi çok daha fazla olmaktadır. Örneğin hava savunma sisteminden gönderilecek güdümlü bir füze için radar ile yapılan mesafe ölçümünde yapılacak en küçük hata, atışın başarısız olmasına neden olabilir. Bu başarısızlık, savunma sistemlerinde büyük bir zafiyete ve buna bağlı olarak onlarca kişinin ölümüne veya büyük maddi kayıplara yol açabilir.

Bu çalışmada, olumsuz hava koşullarında dahi hedefin konumunun radar ile doğru bir şekilde tespit edilmesi için deneysel çalışmalar yapılmıştır. Bu kapsamda hava koşullarının radar ile mesafe ölçümüne etkisi araştırılmıştır. Deney düzeneğinde sabit konumlu bir hedef radar ile sürekli izlenmiştir. Aynı zamanda geliştirilen bir uygulama ile hava durumu verileri (sıcaklık, bağıl nem, görünen sıcaklık ve basınç) kayıt altına alınmıştır.

Radar ile yapılan mesafe ölçümlerinden gerçek mesafe değeri çıkarılarak hata değeri hesaplanmıştır. Hava durumu verileri MLR, SVM, ANFIS, KNN ve ANN yöntemlerinde girdi olarak ve radar mesafe hata verileri çıktı olarak tanımlanmıştır. Tüm modeller için veri setinin %70'i eğitim için, kalan %30'u ise test için ayrılmıştır. Daha sonra hava parametrelerine göre hata değeri tahmin edilmeye çalışılmıştır. Modellerin istatistiksel sonuçları karşılaştırıldığında ANN ve KNN modellerinin diğer modellere göre daha doğru sonuçlar verdiği görülmektedir. KNN9 (K = 9) modeli için MAE 1.15 ve MAPE %7.37 olarak hesaplanmıştır. ANN modeli için MAE 1.06 ve MAPE %7.15 olarak hesaplanmıştır. Sonuçlar analiz edildiğinde ANN yöntemi ile KNN9 yönteminin sonuçlarının birbirine çok yakın olduğu görülmektedir. Ancak az bir farkla ANN modelinin daha yüksek doğrulukta tahminler yapabildiği ortaya koyulmuştur. Böylece radar uygulamalarında hava koşullarından dolayı oluşabilecek ölçüm hatalarını minimum düzeye indirebilmek adına önemli bir çalışma gerçekleştirilmiştir. Bu sayede özellikle hassas ölçümlerin gerektiği uygulamalarda radar mesafe ölçümlerinin her hava koşulunda yüksek doğrulukta gerçekleştirilebilmesi için yenilikçi bir yöntem geliştirilmiştir.

5.2 Öneriler

Farklı mesafelerde bulunan hedefler için yeni çalışmalar yapılarak hedef mesafesinin de modelin doğruluk oranını etkileyebilecek bir faktör olduğu araştırılabilir. Ayrıca gelecek çalışmalar kapsamında tahmin algoritmalarının doğruluk oranları yeterli görülmemeli ve farklı yöntemler araştırılmalıdır. Böylece daha yüksek doğruluk oranlarına ulaşabilecek akademik çalışmaları planlayan araştırmacılara bu tez çalışmasının kılavuz olması ümit edilmektedir.

KAYNAKLAR

Adegoke, A. S., & Onasanya, M. A., 2008, Effect of propagation delay on signal transmission. *Pacific J Sci Technol, 9, 13-19.*

Alan, E. (2013), Yapay sinir ağları yaklaşımı ile curuflarda fosfor kapasitelerinin incelenmesi, Doktora Tezi, *İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü,* 83s.

Anonim, 2019, Aramco saldırısı: 'Suudi Arabistan'daki Patriot'lar ABD'yi Rezil Etti', https://tr.sputniknews.com/ortadogu/201909191040212742-aramco-saldirisi-suudi-arabistandaki-patriotlar-abdyi-rezil-etti/ [Ziyaret Tarihi: 24 Ocak 2022].

Ayan, S., Mehtap, İ. (2018) Fotovoltaik sistemin yapay zeka algoritmasi ile güç tahmini Yüksekl Lisans Tezi, *Kırklareli Üniversitesi Fen Bilimleri Enstitüsü,* 121s.

Bilgiç, H. H., & Mert, İ., 2021, Comparison of different techniques for estimation of incoming longwave radiation. *International Journal of Environmental Science and Technology,* 18(3), 601-618.

Bruder, J. A., Brinkmann, M. C., Whitley, G. R., and Lane, T. L., 2002 Testing of MMW Radar Performance in Adverse Weather Conditions and Clutter Backgrounds, *RADAR 2002, Edinburgh, UK, 2002,* pp. 547-551

Chakchak, J., & Cetin, N. S., 2021, Investigating the impact of weather parameters selection on the prediction of solar radiation under different genera of cloud cover: A case-study in a subtropical location. Measurement, 176, 109159.

Cherkassky, V. and Ma, Y., 2004, Practical Selection of SVM Parameters and Noise Estimation for SVM Regression, *Neural Networks,* 17, 113-126.

Chicco D., Warrens M. J., Jurman G.,2021 The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science, 2021,* 7: e623.

Conyers, L. B., & Goodman, D., 1997, Ground-penetrating radar: an introduction for archaeologists, AltaMira press.

Conyers, L.B., 2004, Ground Penetrating Radar for Archaeology. Alta Mira Press/Sage, *Walnut Creek, California,* 131-159.

Çayıroğlu, İ., 2015, İleri Algoritma Analizi-5 Yapay Sinir Ağları, *Karabük Üniversitesi Mühendislik Fakültesi.*

Doerry, A. W., 2013, Correcting radar range measurements for atmospheric propagation effects, *SPIE 2014 Defense & Security Symposium, Vol. 9077,* pp. 492-503.

Donuk, K. (2014), Şebekeye bağlı fotovoltaik sistemlerde üretilen enerjinin yapay sinir ağları kullanılarak tahmini, Yüksek Lisans Tezi*, Fırat Üniversitesi, Fen Bilimleri Enstitüsü,* 76s.

Erkaymaz, H. (2014), Elektrookulogram (EOG) sinyallerinin incelenmesi ve yapay zaka teknikleri ile modellenmesi, Doktora Tezi, *Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü,* 126s.

Fausett, L., 1994, Fundamentals of Neural Networks - Architectures, Algorithms, and Applications, *Prentice Hall Inc., Englewood Cliffs, NJ.*

Fornaro, G., D'Agostino, N., Giuliani, R., Noviello, C., Reale, D., & Verde, S. (2014). Assimilation of GPS-derived atmospheric propagation delay in DInSAR data processing. *IEEE journal of selected topics in applied Earth observations and remote sensing, 8(2),* 784-799.

Fujita, S., Matsuoka, T., Ishida, T., Matsuoka, K., Mae, S., 2000, A Summary of The Complex Dielectric Permittivity of Ice in The MegaHertz Range and Its

Applications for Radar Sounding of Polar Ice Sheets, *Physics of Ice Core Records,* 185-212.

Genç, A. (2019), GPR'a Dayalı Karamayını Tespiti ve Sınıflandırılması İçin Çoklu-Özellik Füzyonu, Doktora Tezi, *Ortadoğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü,* 122s.

Giles, K., 2015, Russian Ballistic Missile Defense: Rhetoric and Reality. Carlisle Barracks, *PA: U.S. Army War College,* 1-56.

Gözütok, A., 2018, Suriye'nin 30 Yıllık Hava Savunma Sistemi ABD'nin Saldırısına Karşı Koyabildi Mi?, https://www.donanimhaber.com/Suriyenin-30-yillik-hava-savunma-sistemi-ABDnin-saldirisina-karsi-koyabildi-mi--99057 [Ziyaret Tarihi: 24 Ocak 2022].

Gürsoy, M. İ. (2018), Alçak gerilim şebekeleri için durağan ve durağan olmayan güç kalitesi olaylarının tespiti ve sınıflandırılması için yeni bir yaklaşım, Doktora Tezi, *Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü*, 114s.

Güven, A. (2005), Göze ait elektrofizyolojik sinyaller kullanılarak yapay sinir ağları destekli bazı göz hastalıklarının teşhisi, Doktora Tezi, *Erciyes Üniversitesi, Fen Bilimleri Enstitüsü,* 105s.

Hopfield, J. J., 1982, Neural networks and physical systems with emergent collective computational abilities, *Proceedings of the national academy of sciences,* 79(8), 2554-2558.

İçel, Y. (2019), Güneş enerji sistemlerinin performans tahmini için yapay sinir ağları ile modellenmesi ve verimliliğin incelenmesi, Doktora Tezi, *İnönü Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı.*

Kalogirou, S. A., 2001, Artificial neural networks in renewable energy systems applications: a review. Renewable and sustainable energy reviews, 5(4), 373-401.

Kohonen, T., 1972, Correlation matrix memories, *IEEE transactions on computers, 100(4),* 353-359.

Kohonen, T., 2012, Self-organization and associative memory (Vol. 8), *Springer Science & Business Media.*

Korkmaz S. D., 2004 Atmosferde Erime Katmanının Radyo Dalgalarına Etkisi: Yansıtırlık ve Sönümlenme, *URSI 2004,* 387-389.

Küçükdemirci M., 2014, Arkeolojik Alanlarda Manyetik Ve Yer Radarı (GPR) Yöntemi Uygulamaları, Doktora Tezi, *İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Jeofizik Mühendisliği Anabilim Dalı,* 137s.

Leckebusch, J., 2003, Ground-Penetrating Radar: A Modern Three-Dimensional Prospection Method, *Archaeological Prospection, 10, 213-240.*

Lin, C.F., 1991, Modern Navigation, Guidance and Control Processing, *Prentice-Hall.*

Maity, M., Datta, A. K., & Karmakar, P. K., 2009, Effect of climatological parameters on propagation delay through the atmosphere. *Pacific J Sci Technol, 10, 14-19.*

Mellen, C.F.C., 2000, Radar Fundamentals.

Meşecan, I., Uka, A., Stoja, E., & Çiço, B. (2017), Comparison of histograms of oriented gradients and 3-row average subtraction (3RAS) using GprMax, In 2017 6th Mediterranean Conference on Embedded Computing (MECO), pp. 1-5.

Milsom, J. 2003, Field geophysics, J Willey 3th ed., England.

Minsky, M., & Papert, S., 1969, An introduction to computational geometry, *Cambridge tiass., HIT,* 479, 480.

Neri, F., 2001, Introduction to Electronic Defense Systems, Artech House.

Norouzian, F., Marchetti, E., Gashinova, M., Hoare, E., Constantinou, C., Gardner, P., & Cherniakov, M., 2019, Rain attenuation at millimeter wave and low-THz frequencies, *IEEE Transactions on Antennas and Propagation, 68(1), 421-431.*

Norouzian, F., Marchetti, E., Hoare, E., Gashinova, M., Constantinou, C., Gardner, P., & Cherniakov, M., 2018, Low-THz wave snow attenuation, *2018 IEEE International Conference on Radar,* pp. 1-4.

Oguchi, T., 1983, Electromagnetic Wave Propagation and Scattering in Rain and Other Hydrometeors, *Proceedings of The IEEE, Vol. 71, No. 9, 1983,* 1029-1078.

Özdemir, M. (2015), Alt Yapı Elemanlarının Yer Radarı Yöntemi İle Araştırılması, Yüksek Lisans Tezi, *Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü,* 155s.

Özkaya, U., (2020), Derin Öğrenme Yöntemleri ile Gpr B Tarama Görüntülerinin Analizi, Doktora Tezi, *Konya Teknik Ünversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı.*

Öztemel, E., 2012, Yapay Sinir Ağları, Papatya Yayıncılık Eğitim, İstanbul, Türkiye,

Öztürk, M. (2022), A Modified ANFIS System For Aerial Vehicles Control, Doktora Tezi, *İstanbul Teknik Ünversitesi, Lisansüstü Eğitim Enstitüsü,* 136.

Parker, D., Maurer, H. A., 1984, The era of active RF missiles, *Microwave Journal, 27, 24-36.*

Pu, Y., Sun, R., Zheng, X., & Xi, X., 2021, Analysis of the Influence of Time-Varying Factors on LF Ground-Wave Propagation Delay, *2021 IEEE 4th International Conference on Computer and Communication Engineering Technology (CCET), pp. 350-354.*

Pu, Y., Zheng, X., Wang, D., & Xi, X., 2021, Accuracy improvement model for predicting propagation delay of Loran-C signal over a long distance. *IEEE Antennas and Wireless Propagation Letters, 20(4),* 582-586.

Rahimi-Ajdadi, F., Abbaspour-Gilandeh, Y., Mollazade, K., & Hasanzadeh, R. P. (2018), Development of a novel machine vision procedure for rapid and non-contact measurement of soil moisture content, *Measurement,* 121, 179-189.

Riera, J. M., Benarroch, A., Garcia-del-Pino, P., & Pérez-Peña, S., 2020, Preprocessing and assessment of rain drop size distributions measured with a K-band doppler radar and an optical disdrometer. *IEEE Transactions on Instrumentation and Measurement,* 70, 1-8.

Rosenblatt, F., 1958, The perceptron: A probabilistic model for information storage and organization in the brain, *Psychoanalytic Review,* 65, 386-408.

Rumelhart, D.E. and McClelland, J.L., "Parallel Distrubuted Processing: Explorations", in, J.A. Feldman, P.J. Hayes, D.E. Rumelhart (Editors)., 1989, Microstructure of Cognition, *The MIT Press, Cambridge, Massachusetts, London, England.*

Sağıroğlu, Ş., Beşdok E. ve Erler, M., 2003, Mühendislikte Yapay Zeka Uygulamaları-1: Yapay Sinir Ağları, *Ufuk Kitap Kır., Kayseri.*

Saraç T., 2004, Yapay Sinir Ağları, Seminer Projesi, *Gazi Üniversitesi Endüstri Mühendisliği Bölümü Anabilim Dalı.*

Solheim, F. S., Vivekanandan, J., Ware, R. H., & Rocken, C., 1999, Propagation delays induced in GPS signals by dry air, water vapor, hydrometeors, and other particulates, *Journal of Geophysical Research: Atmospheres,* 104(D8), 9663-9670.

Sugiyama, S., Enomoto H., Fujıta S., Fukuı K., Nakazawa F., Holmlund P., 2010, Dielectric permittivity of snow measured along the route traversed in the Japanese–Swedish Antarctic Shin Expedition 2007/08, *Annals of Glaciology,* 51(55), P 9-15.

Tabanna, S.A., 2019, GPR Signal Processing Methods for Water Detection, Master Thesis, *Istanbul Aydın University, Institute of Science And Technology,* 72p.

Tanimu, B.M., 2019, GPR Raw-Data Analysis to Detect Crack Via Wavelets and Deep Learning Methods, Yüksek Lisans, *Yaşar Üniversitesi, Fen Bilimleri Ensitüsü,* 67s.

Tiuri, M.T., Sihvola, A.H., Nyfors, E.G., and Hallikainen, M.T., 1984, The Complex Dielectric Constant of Snow at Microwave Frequencies. IEEE J. Ocean. Eng., 9(5), 377–382.

Tomohiro O., 1983, Electromagnetic Wave Propagation and Scattering in Rain and Other Hydrometeors, Proceedings of the IEEE, Vol. 71, No. 9, 1983, 1029-1078.

Törmä, M., Engdahl, M., 2003, The Effect of Seasonal And Weather Conditions to Land Cover Class Separability in ERS Radar Data, *2003 IEEE International Geoscience and Remote Sensing Symposium,* 2635-2637.

Tuncer, M.A.Ç.,2011, Basamak Frekanslı Yere İşleyen Radar (GPR) İçin Seyreklik Tabanlı Hızlı Yer Altı Görüntüleme Yöntemindeki Problemlere Çözümler, Yüksek Lisans Tezi, *TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü,* 69s.

Üstüner, H., 2006, Radar Arayıcı Başlıklar ve Radar Güdümünün Modellenmesi ve Simülasyonu, Yüksek Lisans Tezi, *Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü,* 149s.

Van Der Kruk, J., Slob, E.C., and Fokkema, J.T., 1998. Background of Ground Penetrating Radar Measurements. Geologie en Mijnbouw, *77, 177-188.*

Widrow, B., & Hoff, M. E., 1960, Adaptive switching circuits. *Stanford Univ Ca Stanford Electronics Labs.*

Xiong, T., Bao, Y., & Hu, Z., 2014, Multiple-output support vector regression with a firefly algorithm for interval-valued stock price index forecasting, *Knowledge-Based Systems,* 55, 87-100.

Yayla, A., 2016, Yağmurun Ku Bant Radar Sinyallerine Etkisi, Yüksek Lisans Tezi, *Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü,* 61s.

Yılmaz, B. (2017), Duvar Arkasındaki Sabit ve Hareketli Hedeflerin Tespit Edilmesi için Ultra Geniş Bantlı Radar Tasarımı, Prototipinin Gerçeklenmesi ve Radar Görüntülerinin Elde Edilmesi, Doktora Tezi, *Mersin Üniversitesi, Fen Bilimleri Enstitüsü, Mersin,* 127s.

Zang, S., Ding, M., Smith, D., Tyler, P., Rakotoarivelo, T., & Kaafar, M. A., 2019, The impact of adverse weather conditions on autonomous vehicles: how rain, snow, fog, and hail affect the performance of a self-driving car, *IEEE Vehicular Technology Magazine,* 14(2), 103-111.

EKLER

XML sorgu sonucunda oluşan cevap


```
<current>
<city id="306569" name="Konya Province">
<coord lon="32.5" lat="38.1667"/>
<country>TR</country>
<timezone>10800</timezone>
<sun rise="2022-05-23T02:33:36" set="2022-05-23T17:00:10"/>
</city>
<temperature value="18.71" min="18.71" max="18.71" unit="celsius"/>
<feels_like value="17.79" unit="celsius"/>
<humidity value="44" unit="%"/>
<pressure value="1007" unit="hPa"/>
<wind>
<speed value="8.13" unit="m/s" name="Fresh Breeze"/>
<gusts value="10.48"/>
<direction value="297" code="WNW" name="West-northwest"/>
</wind>
<clouds value="79" name="broken clouds"/>
<visibility value="10000"/>
<precipitation mode="no"/>
<weather number="803" value="broken clouds" icon="04d"/>
<lastupdate value="2022-05-23T14:42:23"/>
</current>
```